

THESIS / THÈSE

MASTER EN INGÉNIEUR DE GESTION À FINALITÉ SPÉCIALISÉE EN ANALYTICS & DIGITAL BUSINESS

Etude de la volatilité de Chainlink, Maker et Quantum Comparaison avec Bitcoin et Ethereum

Loscalzo, Lucas

Award date:
2019

Awarding institution:
Université de Namur

[Link to publication](#)

General rights

Copyright and moral rights for the publications made accessible in the public portal are retained by the authors and/or other copyright owners and it is a condition of accessing publications that users recognise and abide by the legal requirements associated with these rights.

- Users may download and print one copy of any publication from the public portal for the purpose of private study or research.
- You may not further distribute the material or use it for any profit-making activity or commercial gain
- You may freely distribute the URL identifying the publication in the public portal ?

Take down policy

If you believe that this document breaches copyright please contact us providing details, and we will remove access to the work immediately and investigate your claim.



Etude de la volatilité de Chainlink, Maker
et Quantum - Comparaison avec
Bitcoin et Ethereum

Lucas LOSCALZO

Directeur: Prof. P. GIOT

Mémoire présenté
en vue de l'obtention du titre de
Master 120 en Ingénieur de gestion,
à finalité spécialisée

ANNEE ACADEMIQUE 2019-2020

Préambule

Je tiens tout d'abord à remercier mon promoteur, Pierre Giot, pour sa patience et les réponses qu'il a apporté à mes incertitudes au long de ce mémoire.

Je remercie également mes parents pour m'avoir épaulé tout au long de mes études.

Table des matières

<u>Introduction</u>	4
 <u>Partie théorique</u>	 5
 Chapitre 1 : présentation du concept de crypto-monnaie	 5
Section 1.1. Définition du concept	5
Section 1.2. Histoire brève de leur développement	6
Section 1.3. Fonctionnement basique	7
 Chapitre 2 : définition de la problématique	 10
Section 2.1. Revue de la littérature	10
Section 2.2. Description de la problématique	13
 Chapitre 3 : présentation des données	 13
Section 3.1. Présentation des données brutes	13
Section 3.2. Transformation des données brutes	14
 Chapitre 4 : méthodologie	 15
Section 4.1. Analyse basique des données	15
Section 4.2. Modélisation de la volatilité	18
Section 4.3. Analyse de la volatilité conditionnelle	26
 <u>Partie quantitative</u>	 27
 Chapitre 5 : analyse basique des données	 27

Section 5.1. Analyse graphique	27
Section 5.2. Statistiques descriptives	33
Section 5.3. Tests de stationnarité	37
Chapitre 6 : modélisation de la volatilité	37
Section 6.1. Analyse de l'autocorrélation	37
Section 6.2. Autorégressions	42
Section 6.3. Recherche d'effet ARCH	44
Section 6.4. Recherche des modèles GARCH optimaux	45
Section 6.5. Tests de validité des modèles GARCH optimaux	47
Chapitre 7 : analyse de la volatilité	50
Section 7.1. Analyse des modèles GARCH optimaux	50
Section 7.2. Analyse de la volatilité conditionnelle	53
 <u>Conclusion</u>	 56
 <u>Bibliographie</u>	 57
 <u>Annexes</u>	 60

Introduction

Depuis leur création en 2009 via la naissance du Bitcoin (LANSKY, 2018, p. 20), les crypto-monnaies n'ont cessé de gagner en popularité. A l'heure actuelle, il y aurait environs 3087 crypto-monnaies réparties sur 21042 plateformes de marché et leur capitalisation de marché totale dépasserait les 249 milliards de dollars, dont 66,9 % seraient dus au Bitcoin seul (www.coinmarketcap.com). Par conséquent, cette technologie attire autant l'attention des investisseurs que celle des pouvoirs publics (HOUBEN et SNYERS, 2018, p. 11).

Par ailleurs, ce sujet a également attiré l'attention des chercheurs en finance. En effet, comme nous le verrons dans ce mémoire, un grand nombre de chercheurs se sont penchés sur les propriétés statistiques des crypto-monnaies et plus particulièrement sur les propriétés touchant à sa volatilité. Cependant, pour la plupart, ces études se sont surtout concentrées sur les crypto-monnaies les plus importantes en termes de capitalisation. Beaucoup d'entre elles restent encore à être analysées sous l'angle de leur volatilité.

Ce mémoire ayant pour sujet l'étude de la volatilité de crypto-monnaies, et au vu du trou existant dans la littérature concernant la volatilité de nombreuses monnaies virtuelles, le présent mémoire se penchera sur trois d'entre elles : Chainlink, Maker et Quantum. Ces dernières ont pour spécificité d'être à la fois parmi les plus capitalisées d'entre elles tout en ayant pas encore été analysées de près dans la littérature existante. L'étude de leur volatilité représente donc un apport intéressant à cette même littérature. Deux crypto-monnaies plus établies, Bitcoin et Ethereum seront également analysées en vue de disposer d'une base de comparaison.

Le présent mémoire sera divisé en deux parties : L'une théorique, et l'autre, quantitative. La partie théorique débutera par une introduction au concept de crypto-monnaie, ce qui sera l'objet du chapitre 1. Au cours de ce chapitre, nous verrons les façons dont on peut définir les crypto-monnaies, leur histoire et leur fonctionnement. Le chapitre 2 se focalisant sur la définition de la problématique de ce mémoire, celle-ci sera initiée par une exploration de la littérature existante concernant l'étude de la volatilité des crypto-monnaies et d'autres de leurs propriétés statistiques. Cela permettra de cerner les contours de la problématique au centre de cette thèse de Master et donc, de la décrire. Une fois la problématique définie, le chapitre 3 introduira les données brutes utilisées ainsi que leur transformation. La partie théorique se terminera avec une présentation de la méthodologie au chapitre 4.

La méthodologie utilisée pour cette étude se base principalement sur celle de TSAY (2010), suivant le même parcours pour construire des modèles GARCH(1,1) pouvant représenter les 5 séries de données et plus particulièrement, leur volatilité conditionnelle. La méthodologie de CHU et al. (2017) pour sélectionner le modèle GARCH(1,1) le plus adéquat pour représenter chacune des séries occupe également une grande place de ce mémoire.

Ainsi donc, la partie quantitative débutera par une analyse basique des données au chapitre 5, telle que pratiquée par CHU et al. (2017). Celle-ci consistera en une analyse graphique des données et une analyse de leurs statistiques descriptives. Un test de stationnarité sera également appliqué aux données. Au sein du chapitre 6, nous tenterons de modéliser la volatilité des données en recourant à des modèles GARCH(1,1). Comme l'enseigne TSAY (2010), une analyse de l'autocorrélation, des autorégressions et la recherche d'effet ARCH sont des étapes préalables à cette modélisation. Si effet ARCH il y a, différents modèles GARCH seront appliqués aux données avec différentes lois de distribution pour les innovations afin de déterminer lequel est optimal pour chacune des séries. Ce faisant, nous suivront globalement le même parcours que CHU et al. (2017). La validité des modèles optimaux sera par ailleurs testée via les mêmes méthodes que TSAY (2010). Enfin, dans le chapitre 7, nous analyserons les modèles optimaux et les graphiques de la volatilité conditionnelle qu'ils permettent de générer.

Partie théorique

Chapitre 1 : présentation du concept de crypto-monnaie

Section 1.1. Définition du concept

Définir la crypto-monnaie n'est pas une tâche aisée au vu des nombreuses utilisations que le public fait de ce terme et des nombreuses innovations intervenant au sein de cette technologie. HOUBEN et SNYERS (2018, pp. 20-23) soulignent que de nombreux chercheurs et institutions s'y sont essayés, telles que la Banque Centrale Européenne ou le Fond Monétaire International. C'est d'ailleurs pour cette raison qu'ils ont décidé de

synthétiser dans leur étude les différentes définitions proposées par ces institutions. Ils en arrivent donc à définir la crypto-monnaie comme “une représentation digitale de valeur (i) supposée constituer une alternative de type “pair-à-pair” à la monnaie légale émanant du gouvernement, (ii) utilisée en tant que moyen de paiement (indépendant d’une quelconque banque centrale), (iii) sécurisée par des mécanismes connus tels la cryptographie et (iv) pouvant être convertie en monnaie légale et vice-versa”. LANSKY (2018, p. 19), de son côté, propose la définition suivante : « Les crypto-monnaies sont un système rencontrant 6 conditions:

1. Le système ne requiert pas d’autorité centrale.
2. Le système garde une vue d’ensemble des unités de cette crypto-monnaie ainsi que de leur propriété.
3. Le système définit si de nouvelles unités de cette crypto-monnaie peuvent être créées. Si c’est le cas, il définit alors les circonstances de leur origine et comment déterminer la propriété de ces nouvelles unités.
4. La propriété des unités de crypto-monnaie ne peut être prouvée que de manière cryptographique.
5. Le système autorise les transactions pour lesquelles la propriété d’unités cryptographiques est changée. Un relevé de transaction ne peut être émis que par une entité à même de prouver la propriété de ces unités.
6. Si deux instructions différentes concernant le changement de propriété des mêmes unités cryptographiques sont simultanément émises, le système n’en effectue qu’une des deux. »

Section 1.2. Histoire brève de leur développement

Le premier système de monnaie digitale fut théorisé par David Chaum en 1983. Avec Amos Fiat et Moni Naor, il développe par la suite son concept, notamment en conférant au système la possibilité d’anonymat de l’utilisateur et en empêchant la possibilité de « double-dépense » (LANSKY, 2018, p. 20). En 1990, ils concrétisent alors leur concept pour donner naissance à la première monnaie digitale : le DigiCash (www.wikipedia.org). Par la suite, Stuart Haber et W. Scott Stornetta élaborent en 1997 une structure de données qui précède celle de la blockchain utilisée dans les crypto-monnaies. Le concept de preuve

de travail, est, lui, apporté par Adam Back en 2002. A l'origine, il était alors conçu pour protéger les communications par courrier électronique contre le spam. C'est la combinaison de ces connaissances qui donne naissance au Bitcoin, la toute première crypto-monnaie. Celle-ci fut théorisée dans un article le 3 janvier 2009 par Satoshi Nakamoto, individu ou groupe de personnes dont les identités demeurent encore aujourd'hui inconnues (LANSKY, 2018, p. 20).

A l'heure actuelle, il y aurait environs 3087 crypto-monnaies (www.coinmarketcap.com), dont Factom et Ethereum, tous les deux conçus en 2014, sont considérés par LANSKY (2018, p. 20) comme étant les plus innovantes. Les crypto-monnaies sont réparties sur 21042 plateformes de marché et leur capitalisation de marché totale dépasserait les 249 milliards de dollars, dont 66,9 % seraient dus au Bitcoin seul (www.coinmarketcap.com).

Section 1.3. Fonctionnement basique

Avant de pouvoir utiliser une crypto-monnaie, l'utilisateur doit télécharger un « portefeuille » (BERENTSEN et SCHÄR, 2018, p.5). Il s'agit en fait d'un logiciel permettant de recevoir, stocker et envoyer des unités de crypto-monnaie. Pour ce faire, le portefeuille contient des « clés cryptographiques ». Il permet également de donner un aspect visuel à l'histoire des transactions effectuées par l'utilisateur (HOUBEN et SNYERS (2018, p. 27).

Par la suite, l'utilisateur peut obtenir des unités de crypto-monnaies de différentes manières : il peut les acheter contre de l'argent réel à des plateformes de crypto-monnaies ou à d'autres utilisateurs sur des plateformes de commerce, les gagner grâce au minage, vendre des biens et services en échange, ou encore, les obtenir d'« offreurs » cherchant à augmenter la popularité de leur crypto-monnaie (HOUBEN et SNYERS (2018, p. 25).

Concrètement, les transactions effectuées avec les crypto-monnaies consistent en la diffusion d'une information sur l'ensemble du réseau d'utilisateurs : lorsqu'un individu effectue un paiement en crypto-monnaie, il va informer les autres utilisateurs qu'il transfère son droit de propriété sur certaines unités de cette crypto-monnaie à quelqu'un d'autre. Les autres utilisateurs vont alors à leur tour diffuser cette information jusqu'à ce que l'ensemble du réseau l'ait reçu (BERENTSEN et SCHÄR, 2018, p.5).

En vue d'éviter que quiconque ne diffuse de fausses informations en se faisant passer pour d'autres utilisateurs, le système des crypto-monnaies recourt à la cryptographie asymétrique. Comme dit précédemment, un portefeuille de crypto-monnaie contient des clés cryptographiques. L'une de ces clés, dite « privée », sert à crypter les messages. Il s'agit d'un nombre aléatoire connu uniquement de son utilisateur et lui servant de « signature ». L'autre clé, dite « publique », est dérivée de la clé privée. Connue de tous, elle permet aux autres utilisateurs recevant les messages de décrypter ces derniers. Ce faisant, la clé publique leur permet d'authentifier la provenance du message. On dit alors que la transaction concernée est « légitime ». La clé publique sert également de pseudonyme à son utilisateur (BERENTSEN et SCHÄR, 2018, p.12).

Tandis que la plupart des utilisateurs de crypto-monnaie vont émettre et relayer les informations cryptées, d'autres vont vérifier leur légitimité, les rassembler en « bloc » durant un certain laps de temps et les « miner ». L'idée derrière le minage est de dégager du « bloc candidat » une « empreinte digitale » répondant à une condition spécifique très difficile à obtenir. Si un « mineur » parvient à trouver en premier cette solution et qu'il parvient à convaincre les autres mineurs que son bloc candidat est « valide », il sera alors rémunéré en nouvelles unités de crypto-monnaie (BERENTSEN et SCHÄR, 2018, pp. 5-6).

Pour obtenir cette empreinte digitale, aussi appelée « hash », le mineur utilise une fonction de hachage : dSHA256. Cette fonction va en fait générer une série de chiffres et de lettres à partir du bloc de transactions. Le but du mineur sera d'obtenir un « hash » répondant à une condition spécifique telle que débiter par une série de zéros. Pour ce faire, il devra ajouter un « nonce », un nombre arbitraire, au sein de son bloc candidat. La composition d'un « hash » étant imprévisible, son altération par la modification du bloc candidat l'est tout autant. Le mineur devra donc procéder à un certain nombre d'essais avant de pouvoir trouver la solution. Celle-ci est une preuve que le mineur a procédé à de nombreux essais avant de la trouver. Pour cette raison, on appelle ce genre de système de « système par preuve de travail » (BERENTSEN et SCHÄR, 2018, pp. 6-7).

Lorsqu'un mineur trouve le « nonce » répondant à la condition évoquée précédemment, il soumet son bloc candidat ainsi que sa solution aux autres mineurs. Ces derniers vérifieront que ce bloc respecte certaines règles: premièrement, les transactions contenues dans le bloc doivent être légitimes, c'est-à-dire que les émetteurs doivent posséder les unités qu'ils prétendent dépenser. Les mineurs vont donc à la fois authentifier l'identité des émetteurs grâce à leur clé publique mais aussi vérifier l'historique de leurs transactions

dans la « chaîne de blocs ». Les mineurs doivent aussi s'assurer que le bloc candidat ne contient pas de « double-dépense », c'est-à-dire, deux informations prétendant qu'un utilisateur a transmis son droit de propriété sur les mêmes unités de crypto-monnaie à deux personnes différentes. Normalement, dans un tel cas, le mineur n'est censé prendre en compte que la première qu'il ait reçue. Ils poursuivront en vérifiant si le bloc candidat contient aussi le hash du dernier bloc validé en date. Enfin, ils testeront le « nonce » trouvé en « hachant » de nouveau le bloc candidat pour s'assurer que son hash répond bien à la condition portant sur sa composition (BERENTSEN et SCHÄR, 2018, pp. 10-12).

Une fois que les mineurs se sont assuré que le bloc candidat qu'on leur a communiqué respecte les règles, ils ajoutent son hash aux nouvelles informations qu'ils reçoivent concernant de nouvelles transactions afin de constituer le bloc candidat suivant. C'est lorsque la majorité des mineurs ont ajouté ce hash à leur bloc candidat suivant qu'il est considéré comme validé. De leur côté, les transactions contenues dans le bloc validé sont considérées comme étant confirmées (BERENTSEN et SCHÄR, 2018, p. 12).

C'est parce que chaque bloc validé par les utilisateurs du système contient le hash du précédent que l'on parle de chaîne de blocs. Celle-ci constitue donc un « livre de comptes » reprenant l'ensemble des transactions confirmées ayant été effectuées avec cette crypto-monnaie par ses utilisateurs et dont chacun d'eux possède une copie. Pour le dire autrement, la chaîne de blocs permet à chaque utilisateur de savoir qui possède quelle unité spécifique de crypto-monnaie en n'importe quel point dans le temps. (BERENTSEN et SCHÄR, 2018, pp. 4-12).

Le fonctionnement de la chaîne de blocs est garanti par un mécanisme de consensus entre mineurs menant à un équilibre de Nash. Tout d'abord, rappelons que la condition pour qu'un mineur soit rémunéré de sa preuve de travail est que son bloc candidat soit validé par la majorité des autres mineurs. En d'autres termes, son hash devra être utilisé par la majorité d'entre eux dans leur propre prochain bloc s'il veut être rémunéré. En partant du principe que chacun d'eux respecte les règles, le mineur en question considérera que la meilleure stratégie pour être rémunéré est de soi-même respecter ces règles. De ce fait, bien que chaque utilisateur puisse gérer sa copie de la chaîne de blocs comme il l'entend, chacun d'eux a également un incitant à posséder celle qui fait consensus (BERENTSEN et SCHÄR, 2018, p. 7).

Chapitre 2 : définition de la problématique

Section 2.1. Revue de la littérature

Le sujet de ce mémoire étant l'étude de la volatilité de crypto-monnaies, la littérature explorée dans ce cadre touche aussi bien aux articles traitant du Bitcoin seul qu'à ceux concernant plusieurs crypto-monnaies. De plus, les articles analysant d'autres propriétés statistiques de ces crypto-monnaies et pouvant améliorer l'interprétation de leur volatilité ont aussi été pris en compte.

Parmi les premiers travaux concernant les crypto-monnaies, on retrouve ceux portant sur leurs propriétés statistiques basiques. Tout d'abord, GRONWALD (2014), en menant une analyse statistique du Bitcoin, relève que celui-ci est caractérisé par une forte volatilité. Cependant, il justifie ce comportement par la récence de cette crypto-monnaie. De leur côté, CHAN et al. (2017) analysent la distribution de plusieurs crypto-monnaies et tentent de trouver quelle serait la distribution optimale pour chacune d'elles. Ce faisant, ils montrent que leurs rendements ne sont clairement pas distribués normalement. Ils ajoutent qu'aucune des distributions testées ne correspond parfaitement à toutes les crypto-monnaies analysées. Pour les plus populaires d'entre elles, telles que Bitcoin et Litecoin, la distribution hyperbolique généralisée donne le meilleur ajustement, tandis que pour les crypto-monnaies plus petites, la distribution gaussienne inverse normale, la distribution t généralisée et la distribution de Laplace sont plus avantageuses.

BARIVIERA et al. (2017) examinent plutôt les faits stylisés du marché du Bitcoin. Leur travail met en lumière un certain nombre de ces faits : En premier lieu, malgré le fait que Bitcoin présente une grande volatilité, celle-ci diminue avec le temps. Ensuite, la volatilité du Bitcoin semble être caractérisée par une longue persistance des effets des chocs. Celle-ci n'est pas liée à la liquidité du marché et reste similaire sur différentes échelles de temps (5 à 12 heures). Enfin, un changement de régime semble intervenir en 2014, modifiant le comportement de cette persistance. PHILLIP et al. (2017) mènent également une étude de faits stylisés en l'élargissant à 224 crypto-monnaies. Il ressort de leur travail que les crypto-monnaies possèdent bien une longue mémoire, ainsi qu'un effet levier, une volatilité stochastique et des queues de distribution épaisses.

Beaucoup d'autres études se concentrent plutôt sur la volatilité des crypto-monnaies. Par exemple, OSTERRIEDER et al. (2016) ont montré que les rendements des crypto-monnaies étaient extrêmement volatiles, mais également plus risqués et avec des queues de distributions plus lourdes que dans le cas des monnaies conventionnelles. Ils notent cependant que parmi les crypto-monnaies étudiées, Bitcoin était celle qui présentait le moins de risques. ZHANG et al. (2019) ayant analysé les valeurs extrêmes des séries de données à haute fréquence des quatre principales crypto-monnaies, leurs résultats ont eux aussi révélé que Bitcoin était la moins risquée des quatre, tandis que Ripple était la plus risquée.

Certains axes d'étude, se sont spécifiquement intéressés aux effets asymétriques des chocs sur la volatilité des crypto-monnaies. Ainsi, BAUR et al. (2018) ont tenté de savoir si la volatilité des crypto-monnaies réagissait de manière asymétrique aux chocs passés. Pour ce faire, ils se sont basés sur les données des 20 crypto-monnaies les plus importantes et ont utilisé un modèle TGARCH. Leur conclusion était que cette volatilité augmentait beaucoup plus en réponse à des chocs positifs qu'à des chocs négatifs. A leur suite, KATSIAMPA (2019) a analysé les dynamiques de la volatilité des 5 crypto-monnaies les plus importantes tout en prenant en compte les effets asymétriques des chocs sur les covariances et variances conditionnelles de leurs données. Elle a, dans la foulée, cherché à identifier les événements ayant eu un impact significatif sur le prix des crypto-monnaies qu'elle a étudié. Elle a ainsi montré l'existence d'effets asymétriques pour ces crypto-monnaies, l'existence de corrélations conditionnelles variant en fonction du temps, le caractère positif de ces dernières et l'existence d'interdépendances significatives sur ce marché. Elle découvre également que les dynamiques de la volatilité conditionnelle des crypto-monnaies réagissent particulièrement aux nouvelles majeures. Enfin, ses recherches indiquent qu'il y ait des ruptures structurelles au sein de la variance conditionnelle du Bitcoin et du Litecoin.

La découverte par BARIVIERA (2017) d'un effet de longue persistance dans la volatilité des prix du Bitcoin a suscité l'intérêt des chercheurs pour ce phénomène dont celui de BOURI et al. (2018). Ceux-ci ont analysé la volatilité du Bitcoin en modélisant son rendement tout en prenant en compte la présence de ruptures structurelles. Leur étude a mis en évidence la persistance des chocs dans la volatilité du Bitcoin. CHARFFEDINE et al. (2018) ont montré que cet effet pour les 4 principales crypto-monnaies était réel, et qu'il ne s'agissait pas d'un comportement trompeur créé par des changements structurels.

Un axe de recherche important dans le cadre de ce mémoire est la modélisation optimale des rendements des crypto-monnaies les plus populaires et de leur volatilité. Dans ce

cadre, CHU et al. (2017) ont montré que, parmi les modèles GARCH les plus utilisés en finance, l'IGARCH et le GJR GARCH donnaient les meilleurs résultats. Cependant, du fait qu'ils soupçonnaient l'adéquation de l'IGARCH de provenir d'éventuels changements structurels non pris en compte, CAPORALE et al. (2019) ont à leur suite utilisé des modèles GARCH à fenêtre mobile et ont conclu que les estimations de ceux-ci étaient supérieures à celles des modèles GARCH standards. CHARLES et al. (2019) ont aussi pris en compte la présence de sauts et de ruptures structurelle. Il ressort de leur travail que parmi les modèles GARCH testés, l'IGARCH et l'APARCH avec une distribution de Student pour l'innovation sont les plus adéquats. Leur travail confirme par ailleurs l'importance de prendre en compte les sauts et ruptures structurelles pour la modélisation de la volatilité des crypto-monnaies. CATANIA et al. (2018) comparent les performances de modèles univariés et multivariés pour prédire le comportement des 4 plus importantes crypto-monnaies. Leurs résultats montrent une nette amélioration de la prévision des points du Bitcoin et de l'Ethereum lorsqu'ils utilisent des combinaisons de modèles univariés et une nette amélioration de la prévision de densité des 4 crypto-monnaies en utilisant des modèles multivariés dépendants du temps. Dans son étude se concentrant sur le Bitcoin, KATSIAMPA (2017) montre que le modèle optimal en termes d'ajustement aux données est le modèle CGARCH. Selon elle, ce résultat suggère qu'il est important de disposer d'une composante de variance conditionnelle à court et à long terme. Enfin, OKUR et al. (2019) ont tenté de modéliser la volatilité de Bitcoin, Ethereum et Ripple tout en prenant en compte leur propriété de mémoire longue. Leurs résultats indiquent que le modèle HYGARCH serait le modèle le plus adapté au Bitcoin tandis que le modèle FIGARCH avec une distribution de Student asymétrique et le modèle FIGARCH avec une distribution de Student non-asymétrique produisent de meilleures estimations respectivement pour Ethereum et Ripple. Ils ajoutent que la prise en compte de la mémoire longue améliore les performances de la modélisation GARCH des crypto-monnaies.

Un autre type d'étude intéressant est celui utilisé par SONG et al. (2019). Ce dernier analyse la structure du marché des crypto-monnaies grâce au regroupement hiérarchique et à l'arbre couvrant de poids minimal. Pour mener à bien son étude, il a purgé ses données de l'influence linéaire du Bitcoin et de l'Ethereum, et a effectué son analyse avant et après l'annonce de plans de taxation et de régulation des crypto-monnaies en 2018, ainsi que sur l'ensemble de la période étudiée. Il arrive ainsi à constituer 6 groupes homogènes avant l'annonce et sur l'ensemble de la période étudiée, tandis que seulement 3 groupes restent

homogènes dans tous les cas : celui des crypto-monnaies issues du Bitcoin, celui des crypto-monnaies issues d'Ethereum et enfin, celui des « Dark » crypto-monnaies.

Enfin, on peut également citer l'analyse que JOHN et al. (2019) ont pratiqué sur la demi-vie de la volatilité de certaines crypto-monnaies. Selon leurs résultats, cette demi-vie serait de 3 jours pour le Bitcoin, 6 jours pour le Litecoin et 4 jours pour Ripple.

Section 2.2. Description de la problématique

A l'exception de certaines études cherchant à caractériser le marché des crypto-monnaies dans son ensemble, la majorité des travaux effectués sur des crypto-monnaies particulières ne concernent que les plus importantes d'entre elles. Par conséquent, il serait intéressant que ce mémoire se concentre sur l'étude de la volatilité de 3 crypto-monnaies ayant peu fait l'objet d'analyses tout en étant parmi les plus importantes en termes de capitalisation de marché.

En croisant la littérature avec la liste des crypto-monnaies les plus capitalisées sur le site www.coinmarketcap.com, trois crypto-monnaies intéressantes ressortent. Par ordre de capitalisation de marché, on a : Chainlink (LINK), Maker (MKR) et Quantum (QTUM). Deux crypto-monnaies déjà étudiées et plus populaires seront également analysées en vue de les utiliser comme base de comparaison: Bitcoin (BIT) et Ethereum (ETH).

Ce mémoire consistera donc à étudier la volatilité de LINK, MKR, QTUM, BIT et ETH. Cette étude s'articulera autour de 3 axes : l'analyse basique des données relatives aux 5 crypto-monnaies, la modélisation de leur volatilité et l'analyse de leur volatilité.

Chapitre 3 : présentation des données

Section 3.1. Présentation des données brutes

Les données utilisées pour la partie quantitative de ce mémoire proviennent du site [coinmarketcap](http://coinmarketcap.com), celui-ci revenant souvent au sein de la littérature vue précédemment. Ce site fournit de nombreuses informations telles que les prix (taux de change) d'ouverture et de

fermeture journaliers, et les minimum et maximum journaliers pour chaque crypto-monnaies. L'ensemble de ces prix y sont exprimés en dollars US.

A l'instar de nombreux auteurs tels que CAPORALE et al. (2019, p. 144), KATSIAMPA (2019) ou encore CHARFFEDINE et al. (2018, p. 424), c'est le prix de fermeture journalier des crypto-monnaies qui sera utilisé pour cette étude. Les échantillons prélevés pour LINK, QTUM, BIT et ETH débutent le jour de la création de ces crypto-monnaies. Ces dates correspondent respectivement au 20 septembre 2017, au 24 mai 2017, au 28 avril 2013 et au 7 août 2015. En ce qui concerne MKR, des données étant manquantes pour plusieurs périodes, il a été nécessaire de prendre la date à partir de laquelle les données étaient disponibles de manière régulière en tant que date de début de l'échantillon, à savoir le 20 novembre 2017. Quant à la date de fin des 5 échantillons, celle-ci a été fixée au 30 août 2019. Ce faisant, ce mémoire dispose de 710 observations pour LINK, 649 observations pour MKR, 829 observations pour QTUM, 2316 observations pour BIT et 1485 observations pour ETH.

Section 3.2. Transformation des données brutes

Les échantillons constitués à partir des données de www.coinmarketcap.com ne seront pas utilisés tels quels. A la place des prix de fermeture journaliers des 5 crypto-monnaies, ce sont les log-rendements calculés à partir de ces derniers qui seront utilisés. En effet, alors que les prix des actifs sont communément admis comme non-stationnaires en finance, les log-rendements présentent, eux, l'avantage d'être stationnaires (TSAY, 2010, p. 76). Or, la stationnarité étant une hypothèse ayant servi à élaborer la plupart des procédures qui seront utilisées dans la partie quantitative, il est important que les données respectent cette condition (TSAY, 2010).

Mathématiquement, les log-rendements de fermeture journaliers des crypto-monnaies au temps t , y_t , sont obtenus des prix de fermeture journaliers de ces dernières aux temps $t-1$ et t , P_{t-1} et P_t , par (TSAY, 2010, p. 5) :

$$y_t = \log(P_t) - \log(P_{t-1}) \quad (3.1)$$

De par cette fonction, on comprend que les 5 échantillons diminueront tous d'une observation puisqu'il n'est pas possible de calculer le log-rendement pour la première date des échantillons de départ. On aura donc 709 observations pour LINK, 648 observations pour MKR, 828 observations pour QTUM, 2315 observations pour BIT et 1484 observations pour ETH. Quant à leur nouvelle date de départ, on aura respectivement le 21 septembre 2017, le 25 mai 2017, le 29 avril 2013, le 7 août 2015 et le 21 novembre 2017.

Chapitre 4 : méthodologie

Section 4.1. Analyse basique des données

Avant de débiter l'analyse de la volatilité des 5 crypto-monnaies, une analyse basique des données sera pratiquée. Celle-ci consistera à observer les graphiques en courbes des log-rendements journaliers, leur valeur absolue et leur carré et ce, afin de déceler d'éventuels motifs intéressants. Des statistiques sommaires telles que la moyenne, le kurtosis ou encore la statistique de Jarque-Bera seront également considérées en vue de caractériser les 5 séries. C'est notamment le caractère normal de leur distribution qui sera mesuré à travers ces statistiques et le graphique de leur distribution.

Le test de Jarque-Bera est d'une grande utilité pour mesurer le caractère normale d'une distribution car sa statistique permet de tester directement l'hypothèse nulle de normalité des données. Cette statistique se calcule avec :

$$JB = \frac{n-k}{6} \left(S^2 + \frac{(K-3)^2}{4} \right) \quad (4.1)$$

Dans cette expression, n représente le nombre d'observations, k, le nombre de variables explicatives si les données proviennent des résidus d'une régression linéaire, sinon k reste nul, S représente le coefficient d'asymétrie de l'échantillon testé et K, le coefficient d'aplatissement de l'échantillon testé. Intuitivement, sachant qu'une loi normale a un coefficient d'asymétrie de 0 et d'aplatissement de 3, on comprend que si les données suivent une loi normale, la statistique du test s'approche alors de 0. Plus formellement, puisque cette

statistique suit asymptotiquement une loi du χ^2 à deux degrés de liberté, lorsqu'elle est inférieure à la valeur critique correspondante à cette loi, on ne rejette pas H_0 au seuil α . Dans le cas contraire, cela signifierait que les données ne suivent pas une loi normale. Dans une autre perspective, lorsque la p-value tirée de la loi du χ^2 à deux degrés de liberté est inférieure à α , on rejette alors H_0 et inversement (www.wikipedia.org).

Avant de passer à la modélisation de la volatilité des 5 séries et à l'analyse de celle-ci, un test de stationnarité sera pratiqué sur les données. En effet, comme précisé dans la section 3.2, la stationnarité est une condition importante que les données doivent vérifier pour que les procédures qui seront utilisées aient un sens. On s'attend cependant à ce que les séries soient effectivement stationnaires puisqu'il s'agit de log-rendements.

Le test augmenté de Dickey-Fuller (www.real-statistics.com) sera utilisé pour déterminer si les séries sont stationnaires ou pas. Pour comprendre la logique de ce test, il faut partir du test de Dickey-Fuller simple. Ce dernier estime 3 sortes de modèles :

L'un sans constante ni dérive temporelle :

$$y_i = \phi y_{i-1} + \varepsilon_i \quad (4.2)$$

Le second avec constante mais toujours sans dérive temporelle :

$$y_i = \alpha + \phi y_{i-1} + \varepsilon_i \quad (4.3)$$

Et le dernier avec constante et dérive temporelle :

$$y_i = \alpha + \mu t + \phi y_{i-1} + \varepsilon_i \quad (4.4)$$

où $|\phi| \leq 1$ et ε_i est un bruit blanc. Si $|\phi| = 1$, nous avons ce qu'on appelle une racine unitaire. En particulier, si $\phi = 1$, nous avons une marche aléatoire (sans dérive), qui n'est pas stationnaire. En fait, si $|\phi| = 1$, le processus n'est pas stationnaire, alors que si $|\phi| < 1$, le

processus l'est. Nous ne considérerons pas le cas où $|\varphi| > 1$ puisque dans ce cas le processus est explosif et augmente avec le temps. Le test de Dickey-Fuller consisterait alors à tester $H_0: \varphi = 1$ contre $H_a: \varphi < 1$.

Par facilité, concentrons-nous sur le 1^{er} modèle. En prenant la 1ère différence de celui-ci, on obtient :

$$y_i - y_{i-1} = \varphi y_{i-1} - y_{i-1} + \varepsilon_i \quad (4.5)$$

Ou encore :

$$\Delta y_i = (\varphi - 1) y_{i-1} + \varepsilon_i \quad (4.6)$$

En prenant $\beta = (\varphi - 1)$, l'équation devient :

$$\Delta y_i = \beta y_{i-1} + \varepsilon_i \quad (4.7)$$

Pour laquelle nous devons tester $H_0: \beta = 0$ contre $H_a: \beta < 0$.

Dans l'hypothèse alternative, si b est l'estimation par la méthode des moindres carrés ordinaires (MCO) de β , et si $f = 1 + b$ est l'estimation MCO de φ , alors pour n assez grand, $\sqrt{n}(\varphi - f) \sim N(0, s.e.)$ et $s.e. = \sqrt{(1 - \varphi^2)}$.

Pour calculer cette statistique, nous pouvons utiliser l'approche habituelle de la régression linéaire. Cependant, lorsque H_0 tient, le coefficient t ne suit pas une distribution normale et nous ne pouvons donc pas utiliser le test t habituel. Au lieu de cela, ce coefficient suit une distribution τ et le test consiste donc à déterminer si la statistique τ (qui est

équivalente à la statistique t habituelle) est inférieure à τ_{crit} sur la base d'un tableau de valeurs de statistiques critiques τ présentées dans le tableau de Dickey-Fuller. Dans ce cas, l'hypothèse nulle de non-stationnarité de la série temporelle serait alors rejetée.

Le test augmenté de Dickey-Fuller étend la 1^{ère} version aux processus autorégressifs d'ordre supérieur à 1. Le 1^{er} modèle vu précédemment a donc la forme :

$$\Delta y_i = \beta y_{i-1} + \sum_{j=2}^p \gamma_j \Delta y_{i-j+1} + \varepsilon_i \quad (4.8)$$

Le reste de la procédure reste cependant la même. Il est également à noter que p , l'ordre du modèle autorégressif, est déterminé par le critère d'information d'Akaike (voir plus loin).

Section 4.2. Modélisation de la volatilité

Pour modéliser la volatilité des 5 séries, ce mémoire testera plusieurs modèles GARCH standards afin de trouver lesquels s'adaptent le mieux aux données, à l'instar de CHU et al. (2017). Pour la construction de ces modèles, la même procédure que celle présentée par TSAY (2010, pp. 113-140) sera suivie.

La 1^{ère} étape de la modélisation va consister à analyser l'autocorrélation des log-rendements. Le but de cette analyse est d'avoir une idée de l'ordre de l'autocorrélation des séries qui sera à priori également l'ordre de leurs équations d'autorégression (TSAY, 2010, p. 46). Cet ordre pourrait aussi être celui de l'équation de moyenne des modèles GARCH qui seront utilisés (TSAY, 2010, p. 113). Cependant, comme le précise TSAY (2010, p. 114), pour la plupart des séries de rendements, il n'y a en général pas ou peu d'autocorrélation, au point que la fonction de moyenne des modèles GARCH utilisés se résume souvent à une constante.

Les outils utilisés pour analyser l'autocorrélation des 5 séries seront les fonctions d'autocorrélation simple et partielle, ainsi que le test de Ljung-Box (TSAY, 2010, pp. 30-34).

Le Runs test (www.support.sas.com) sera également employé pour rendre l'analyse plus robuste.

La fonction d'autocorrélation simple exprime le niveau de corrélation ρ_l entre y_t et y_{t-l} , où l représente le nombre de pas dans le passé par rapport à t . Mathématiquement, cette fonction a la forme suivante :

$$\rho_l = \frac{\text{cov}(y_t, y_{t-l})}{\sqrt{\text{var}(y_t) \text{var}(y_{t-l})}} \quad (4.9)$$

Il est à noter que $\rho_0 = 1$, $\rho_l = \rho_{-l}$ et $-1 \leq \rho_l \leq 1$. De plus, sous l'hypothèse que y_t suit un processus faiblement stationnaire, il n'est pas sériellement corrélé si et seulement si $\rho_l = 0$. On peut ajouter que sous certaines conditions générales, ρ_l peut être empiriquement estimé de manière consistante par :

$$r_l = \frac{\sum_{t=1}^{n-l} (y_t - \bar{y})(y_{t+l} - \bar{y})}{\sum_{t=1}^n (y_t - \bar{y})^2} \quad (4.10)$$

$$\text{Où } \bar{y} = \frac{1}{n} \sum_{t=1}^n y_t \quad (4.11)$$

Il est possible de tester $H_0 : \rho_l = 0$ contre $H_a : \rho_l \neq 0$ grâce à la statistique suivante :

$$t \text{ ratio} = \frac{r_l}{\sqrt{\text{var}(r_l)}} \quad (4.12)$$

Avec :

$$\text{var}(r_l) = \frac{1}{n} \left(1 + 2 \sum_{j=1}^{l-1} r_j^2 \right) \quad (4.13)$$

En effet, si y_t est une série Gaussienne stationnaire satisfaisant $p_j = 0$ pour $j > 1$, t ratio est alors asymptotiquement distribué selon une loi normale standardisée. Lorsque $|t \text{ ratio}| > Z_{\alpha/2}$, le $100(1-\alpha/2)$ e percentile de la loi normale standardisée, H_0 doit être rejetée.

Cependant, nous utiliserons moins l'expression mathématique de cette fonction que son expression graphique : l'autocorrélogramme simple. Constitué de pics verticaux disposés le long d'un axe horizontal, l'autocorrélogramme associe le niveau d'autocorrélation en ordonnée, au nombre de décalages dans le passé en abscisse. Deux lignes discontinues sont situées de part et d'autre de l'abscisse pour représenter l'intervalle de confiance associé au test de nullité précédemment évoqué. Lorsqu'un pic dépasse l'une de ces 2 lignes, le niveau d'autocorrélation associé à son décalage est considéré comme étant significativement différent de 0.

L'interprétation de l'autocorrélogramme simple se fait sur base du motif dessiné par les premiers pics de la figure : lorsque le ou les premiers pics consécutifs sont significatifs tout en déclinant progressivement avec le décalage, c'est un signe de la présence d'autocorrélation dans la série. Cette interprétation doit cependant être complétée par celle de l'autocorrélogramme partiel. Il se peut en effet que la significativité de pics de l'autocorrélogramme simple provienne d'un effet de propagation de ceux qui les précèdent. L'autocorrélogramme partiel a pour spécificité de présenter le niveau d'autocorrélation associé à chaque décalage en le purgeant de l'effet de ceux qui le précèdent. Lorsqu'en plus du déclin progressif des pics significatifs de l'autocorrélogramme simple, on observe un déclin brutal parmi les premiers pics significatifs sur l'autocorrélogramme partiel, le décalage associé au pic précédant ce déclin représente l'ordre d'autocorrélation de la série.

Le test de Ljung-Box, de son côté, utilise une statistique, $Q(m)$, afin de tester l'hypothèse nulle $H_0 : \rho_1 = \dots = \rho_m = 0$ contre l'hypothèse alternative $H_a : \rho_i \neq 0$ pour certains $i \in \{1, \dots, m\}$. Sous l'hypothèse que la série testée est une séquence i.i.d. dont les moments répondent à certaines conditions, $Q(m)$ est asymptotiquement une variable aléatoire suivant une loi du χ^2 avec m degrés de liberté. Lorsque $Q(m) > \chi_{\alpha}^2$, où χ_{α}^2 est la valeur critique de la loi du χ^2 avec m degrés de liberté associé à une erreur de type I à $\alpha\%$, H_0 doit être rejetée. $Q(m)$ s'exprime mathématiquement par :

$$Q(m) = n(n+2) \sum_{l=1}^m \frac{r_l^2}{n-l} \quad (4.14)$$

Il est à noter que des études suggèrent de prendre $m \approx \log(n)$ pour une analyse plus performante de l'autocorrélation (TSAY, 2010, p. 33).

Le Runs test, lui, est un test non-paramétrique visant entre-autre à déterminer la présence d'autocorrélation dans une série. Pour ce faire, il compare les données de la série à un seuil (souvent la médiane de la série, mais aussi la moyenne) en opérant leur différence mathématique. Lorsqu'une séquence de différences consécutives est positive ou négative, cette séquence se nomme « Run ». Si le nombre de Runs se trouve à l'intérieur de l'intervalle de confiance de la loi normale approximée pour 95% de significativité, on ne rejette pas l'hypothèse nulle H_0 d'absence d'autocorrélation dans la série. Dans le cas contraire H_0 doit être rejetée, et c'est l'hypothèse alternative H_a de présence d'autocorrélation dans la série qui est conservée. Mathématiquement, ce test se présente de la façon suivante :

En utilisant le nombre total d'observations n , le nombre total de différences positives n_1 et le nombre total de différences négatives n_2 , on calcule la moyenne et la variance qui serviront à construire l'intervalle de confiance à 95% de la loi normale approximée :

$$\text{Moyenne: } \mu_R = \frac{2n_1n_2}{n} + 1 \quad (4.15)$$

$$\text{Variance: } \sigma_R^2 = \frac{2n_1n_2(2n_1n_2 - n)}{n^2(n-1)} \quad (4.16)$$

$$\text{Borne inférieure : } \mu_R - 1,96\sigma_R \quad (4.17)$$

$$\text{Borne supérieure : } \mu_R + 1,96\sigma_R \quad (4.18)$$

Si le nombre de runs R se trouve à l'intérieur des 2 bornes de l'intervalle de confiance de la loi normale approximée, on ne rejette pas H_0 et inversement.

La 2^e étape consistera ensuite à modéliser des autorégressions d'ordre similaire à ceux indiqués par l'autocorrélogramme partiel (TSAY, 2010, pp. 46-47). L'idée est qu'en réussissant à capturer la dépendance linéaire qu'il y a au sein des données, les résidus des modèles autorégressifs en seront purgés. Ces résidus pourront de ce fait être utilisés pour y tester la présence d'effet ARCH lors de l'étape suivante sans que la dépendance linéaire ne biaise les résultats du test (TSAY, 2010, p. 113). Un modèle autorégressif d'ordre p , noté $AR(p)$, où p est un entier non-négatif, se définit par (TSAY, 2010, p. 38) :

$$y_t = \varphi_0 + \varphi_1 y_t + \dots + \varphi_p y_{t-p} + \varepsilon_t \quad (4.19)$$

Si la p -valeur associée au t de Student des coefficients φ_i s'avère être supérieure à 5%, cela signifiera que ce coefficient n'est pas significativement différent de 0 et qu'un recalibrage de l'équation sera nécessaire.

La recherche d'effet ARCH sera la 3^e étape de la modélisation de la volatilité, celle qui indiquera s'il est pertinent d'utiliser des modèles GARCH dans le cadre de cette étude. L'effet ARCH peut se définir comme une dépendance quadratique des résidus des autorégressions précédentes avec leurs valeurs passées et qui n'est pas due à de l'autocorrélation (TSAY, 2010, pp. 115-116). C'est la raison pour laquelle le test de Ljung-Box sera appliqué au carré de ces résidus. Si ce test montre que ces résidus au carré sont sérielement corrélés, cela signifiera qu'il existe un effet ARCH dans les données des séries (TSAY, 2010, p. 114) et qu'il est pertinent d'utiliser les modèles de la famille GARCH.

La 4^e étape de la modélisation de la volatilité sera la recherche des modèles GARCH qui s'adaptent le mieux aux données des 5 séries. Par facilité, les modèles testés seront d'ordre 1. Il s'agira du SGARCH(1,1), du IGARCH(1,1), du TGARCH(1,1), du EGARCH(1,1) et du CGARCH(1,1). L'idée derrière la modélisation en GARCH est que si les résidus ε_t des autorégressions précédentes ne sont pas autocorrélés mais tout de même dépendants, cette dépendance peut être représentée par une fonction quadratique des valeurs antérieures de ces résidus (TSAY, 2010). Mathématiquement, si un effet ARCH a été détecté dans les résidus des autorégressions, les log-rendements des crypto-monnaies peuvent être exprimés par :

$$y_t = \mu_t + \varepsilon_t \quad (4.20)$$

Avec,

$$\mu_t = \varphi_0 + \varphi_1 y_t + \dots + \varphi_p y_{t-p} \quad (4.21)$$

$$\varepsilon_t = \sigma_t z_t \quad (4.22)$$

où μ_t , la moyenne conditionnelle des log-rendements, s'exprime par l'équation d'autorégression modélisée lors de la 2^e étape. Elle est ici l'équation de moyenne des modèles GARCH. Les résidus de l'autorégression de la 2^e étape sont toujours représentés par ε_t , mais sont ici appelés l'« innovation » des modèles GARCH. Dans l'équation (4.22), ε_t est une fonction de σ_t , la volatilité conditionnel, et de z_t , une séquence de variables aléatoires iid de moyenne 0 et de variance 1 (TSAY, 2010, pp. 111-116).

Les modèles GARCH sont également composés d'une équation de volatilité conditionnelle dont la forme peut varier en fonction du type de modèle GARCH employé. Ainsi, pour le GARCH(1,1) standard, noté SGARCH(1,1), on aura (CHU et al., 2017, p. 4) :

$$\sigma_t^2 = \alpha_0 + \alpha_1 \varepsilon_{t-1}^2 + \beta_1 \sigma_{t-1}^2 \quad (4.23)$$

avec $\alpha_1 > 0$, $\beta_1 > 0$, $\alpha_0 > 0$ et $(\alpha_1 + \beta_1) < 1$. La dernière contrainte est indispensable pour que l'hypothèse de stationnarité faible tienne (CHU et al., 2017, p. 4) tandis que les autres assurent que $\sigma_t > 0$ (DIVINO et al., 2009, p. 10). Selon CAMPBELL et al. (1996, p. 483), α_1 exprime dans quelle mesure un choc sur la volatilité aujourd'hui se répercute sur celle de la période suivante. $(\alpha_1 + \beta_1)$, lui, mesurerait la persistance de cet effet dans le temps. Au plus le résultat de cette somme est proche de 1, au plus cette persistance est élevée (CHAN, 2010, p. 106). L'Integrated GARCH(1,1), noté IGARCH(1,1), est un cas particulier du SGARCH(1,1) où $(\alpha_1 + \beta_1)$, le « paramètre de persistance », vaut 1. Par conséquent, ce modèle est strictement stationnaire (CHU et al., 2017, p. 4). Le Threshold GARCH(1,1), noté TGARCH(1,1), se distingue du SGARCH(1,1) en ce qu'il prend en compte l'effet asymétrique des chocs positifs et négatifs sur la volatilité (CHU et al., 2017, p. 4). Son équation de volatilité s'écrit :

$$\sigma_t^2 = \alpha_0 + \alpha_1 \varepsilon_{t-1}^2 + \gamma_1 I_{t-1} \varepsilon_{t-1}^2 + \beta_1 \sigma_{t-1}^2 \quad (4.24)$$

où $\gamma_1 > 0$ tandis que $I_{t-1} = 1$ si $\varepsilon_{t-1} \leq 0$ et $I_{t-1} = 0$ si $\varepsilon_{t-1} > 0$. Ainsi donc, un choc positif ε_{t-1} en $t-1$ augmentera la volatilité conditionnelle de $\alpha_1 \varepsilon_{t-1}^2$ en t , alors qu'un choc négatif ε_{t-1} l'augmentera de $(\alpha_1 + \gamma_1) \varepsilon_{t-1}^2$. De son côté, le paramètre de persistance s'exprimera par $(\alpha_1 + \beta_1 + \gamma_1)$, où γ est la valeur attendue de ε_{t-1} (CHU et al., 2017, p. 4). L'Exponential GARCH(1,1), noté EGARCH(1,1), a une équation de volatilité conditionnelle de la forme :

$$\log(\sigma_t^2) = \alpha_0 + \alpha_1 \varepsilon_{t-1} + \theta_1 |\varepsilon_{t-1} - E(\varepsilon_{t-1})| + \beta_1 \log(\sigma_{t-1}^2) \quad (4.25)$$

où $\theta_1 > 0$ et a pour rôle de capturer l'effet de la magnitude des chocs sur la volatilité conditionnelle tandis que α_1 en capturera plutôt l'effet du signe. Dans le cas de ce modèle, le paramètre de persistance est β_1 (CHU et al., 2017, p. 4). Enfin, le Component GARCH(1,1), noté CGARCH(1,1), décompose sa volatilité conditionnelle en deux équations (CHU et al., 2017, p. 5) :

$$\sigma_t^2 = q_t + \alpha_1 (\varepsilon_{t-1}^2 - q_{t-1}) + \beta_1 (\sigma_{t-1}^2 - q_{t-1}) \quad (4.26)$$

$$q_t = \alpha_0 + \psi q_{t-1} + \omega (\varepsilon_{t-1}^2 - \sigma_{t-1}^2) \quad (4.27)$$

où $\psi > 0$ et $\omega \geq 0$ (CHU et al., 2017, p. 5). La première équation, appelée composante transitoire, décrit la volatilité conditionnelle de court-terme σ_t . Quant à la seconde, appelée composante permanente, elle décrit la volatilité de long-terme q_t . Alors que le paramètre de persistance s'exprime avec $(\alpha_1 + \beta_1)$ pour la composante transitoire, celle de la composante permanente est représentée par ψ (www.eviews.com). Par conséquent, pour que l'hypothèse de stationnarité faible tienne, il faut que $(\alpha_1 + \beta_1) < 1$ et $\psi < 1$ (CHU et al., 2017, p. 5). Par ailleurs, il faut préciser que l'innovation de ces différents modèles pourra être distribuée selon 3 lois : la loi normale, celle de Student et la loi normale généralisée. Ce sont donc au total 15 modèles qui seront testés pour chacune des 5 crypto-monnaies.

L'ensemble de ces modèles seront estimés par la méthode du maximum de vraisemblance. Le modèle optimal pour chaque crypto-monnaie sera alors sélectionné sur base de 3 critères d'information (CHU et al., 2017, p. 6) :

Le Critère d'Information d'Akaike, noté AIC, se définit par :

$$AIC = 2x - 2\log(L(\hat{\Theta})) \quad (4.28)$$

De son côté, le Critère d'Information Bayésien, noté BIC, est défini par :

$$BIC = x\log(n) - 2\log(L(\hat{\Theta})) \quad (4.29)$$

Enfin, celui d'Hannan-Quinn, noté HQC, se définit par :

$$HQC = -2\log(L(\hat{\Theta})) + 2x\log(\log(n)) \quad (4.30)$$

où dans ces 3 équations, x représente le nombre de paramètres inconnus, n , le nombre d'observations et $L(\hat{\Theta})$, le maximum de vraisemblance du modèle. Plus la valeur de ces critères est faible, plus l'adéquation du modèle aux données est élevée.

La dernière étape de la modélisation de la volatilité consistera alors à tester la validité des modèles sélectionnés comme étant optimaux (TSAY, 2010, pp. 122-123). Pour ce faire, les résidus standardisés des modèles seront analysés. Ceux-ci se définissent par :

$$\tilde{\varepsilon}_t = \frac{\varepsilon_t}{\sigma_t} \quad (4.31)$$

En principe, si le modèle GARCH a correctement été spécifié, les résidus standardisés devraient former une séquence de variables aléatoires i.i.d.. Il est donc possible de vérifier la validité de l'équation de moyenne du modèle optimal en appliquant le test de Ljung-Box sur les résidus standardisés du modèle. La validité de l'équation de volatilité, elle, sera vérifiée en appliquant de nouveau le test de Ljung-Box, mais cette fois-ci sur le carré des résidus standardisés.

Section 4.3. Analyse de la volatilité conditionnelle

Après que les modèles GARCH optimaux aient été validés, la volatilité conditionnelle des 5 crypto-monnaies peut être analysée. Cette analyse portera en premier lieu sur les paramètres de l'équation de volatilité des modèles optimaux. Cela concernera le paramètre α_1 , le paramètre de persistance et la demi-vie de la volatilité. Cette dernière mesure le temps requis pour la volatilité de revenir à mi-chemin de sa moyenne non-conditionnelle (JOHN et al., 2019, pp. 18-19). Elle se calcule de la façon suivante :

$$\tau = \frac{\log\left(\frac{\alpha_1 + \beta_1}{2}\right)}{\log(\alpha_1 + \beta_1)} \quad (4.32)$$

L'étape finale de l'analyse de la volatilité des 5 crypto-monnaies consistera à décrire l'expression graphique de leur volatilité conditionnelle. Celle-ci sera obtenue à partir des modèles optimaux.

Partie quantitative

Chapitre 5 : analyse basique des données

Section 5.1. Analyse graphique










Figure 5.1. Evolution des log-rendements journaliers des 5 crypto-monnaies.









Figure 5.2. Evolution des log-rendements journaliers absolus des 5 crypto-monnaies.






Figure 5.3. Evolution du carré des log-rendements journaliers des 5 crypto-monnaies.

Tout d'abord, nous pouvons voir que les graphiques de l'évolution des log-rendements de la figure 5.1 mettent en évidence la présence de clusters pour les 5 crypto-monnaies. Ce constat est renforcé par les graphiques de l'évolution de la valeur absolue des log-rendements et ceux de leur carré sur les figures 5.2 et 5.3.

Section 5.2. Statistiques descriptives

Tableau 5.1. Statistiques descriptives des log-rendements journaliers des 5 crypto-monnaies.

	LINK	MKR	QTUM	BIT	ETH
Observations	709	648	828	2315	1484
Moyenne	0,003185	0,000865	-0,001294	0,001844	0,00277
Médiane	-0,0044	-0,000686	-0,002139	0,001944	-0,000769
Maximum	0,484157	0,458461	0,559905	0,357451	0,412337
Minimum	-0,317828	-0,346203	-0,451746	-0,266198	-1,302106
Ecart-type	0,086366	0,064273	0,08626	0,043306	0,073644
Coefficient d'asymétrie	0,669216	0,583888	0,886188	-0,174592	-3,387796
Coefficient d'aplatissement	6,501205	10,58157	11,97359	10,5787	71,46111
Jarque-Bera	415,0555	1588,787	2886,498	5552,011	292646,8
Probabilité	0	0	0	0	0


Par la suite, le tableau 5.1 nous apprend que LINK a une moyenne de log-rendements plus élevée que ses consœurs. Il est suivi par les 2 crypto-monnaies de référence, ETH et BIT, ce qui est plus ou moins cohérent avec le niveau de capitalisation de ces dernières (www.coinmarketcap.com). On remarquera par ailleurs que QTUM a non seulement la moyenne de log-rendements la plus basse, mais que celle-ci est également négative.



On constate aussi dans ce même tableau que LINK a la volatilité non-conditionnelle la plus élevée, tandis que celle d'ETH est moyenne et celle de BIT, la plus faible. Il est à noter que le dernier résultat concernant BIT est cohérent avec l'étude d'OSTERRIEDER et al. (2016) qui avait déjà montré que de toutes les crypto-monnaies qu'ils avaient étudiées, BIT était celle qui présentait le moins de risque.

Le coefficient d'asymétrie est positif pour les 3 crypto-monnaies étudiées, traduisant une asymétrie à gauche alors que le coefficient négatif pour les 2 crypto-monnaies de référence traduirait plutôt une asymétrie à droite. Quoiqu'il en soit, ils sont tous différents du coefficient d'une distribution normale (valant 0). Leur kurtosis est lui aussi plus élevé que celui d'une distribution normale (valant 3). On constate cependant que parmi les 5 séries,

celle du log-rendement de MKR possède le coefficient d'asymétrie et le kurtosis les plus proches de la loi normale. En outre, l'allure des histogrammes à la figure 5.4 confirme toutes ces observations.

Le test de normalité de Jarque-Bera confirme lui aussi la non-normalité des 5 distributions décrites. En effet, la p-value associée à ce test est nulle pour chacune des séries, impliquant ainsi le rejet de l'hypothèse nulle du test selon laquelle les données seraient normalement distribuées. En cela, ces observations rejoignent les conclusions de CHU et al. (2015) et CHAN et al. (2017) qui eux aussi avaient constaté la non-normalité des distributions de différentes crypto-monnaies, et notamment de celles de Bitcoin et Ethereum.









Figure 5.4. Histogrammes des log-rendements journaliers des 5 crypto-monnaies.

Section 5.3. Tests de stationnarité

La statistique τ du test augmenté de Dickey-Fuller au tableau 5.2 est inférieure aux valeurs critiques correspondantes pour des seuils de significativité de 1, 5 et 10% et ce, pour chacune des 5 crypto-monnaies. Ces résultats impliquent donc le rejet de l'hypothèse nulle de non-stationnarité du test pour les 5 séries.

Tableau 5.2. Résultats du test augmenté de Dickey-Fuller pour les 5 crypto-monnaies

	LINK	MKR	QTUM	BIT	ETH
Statistique τ	-26,3736	-24,7801	-27,2345	-48,2559	-41,1484
Valeur critique à 1%	-3,4394	-3,4402	-3,438	-3,433	-3,4346
Valeur critique à 5%	-2,8654	-2,8658	-2,8648	-2,8626	-2,8633
Valeur critique à 10%	-2,5689	-2,5691	-2,5686	-2,5674	-2,5677

Chapitre 6 : modélisation de la volatilité

Section 6.1. Analyse de l'autocorrélation

Le nombre de pas dans le passé pris en considération pour l'analyse de l'autocorrélation seront de $m = \log(709) = 6,56 \approx 7$ pour LINK, $m = \log(648) = 6,47 \approx 6$ pour MKR, $m = \log(828) = 6,72 \approx 7$ pour QTUM, $m = \log(2315) = 7,75 \approx 8$ pour BIT et enfin, $m = \log(1484) = 7,3 \approx 7$ pour ETH.

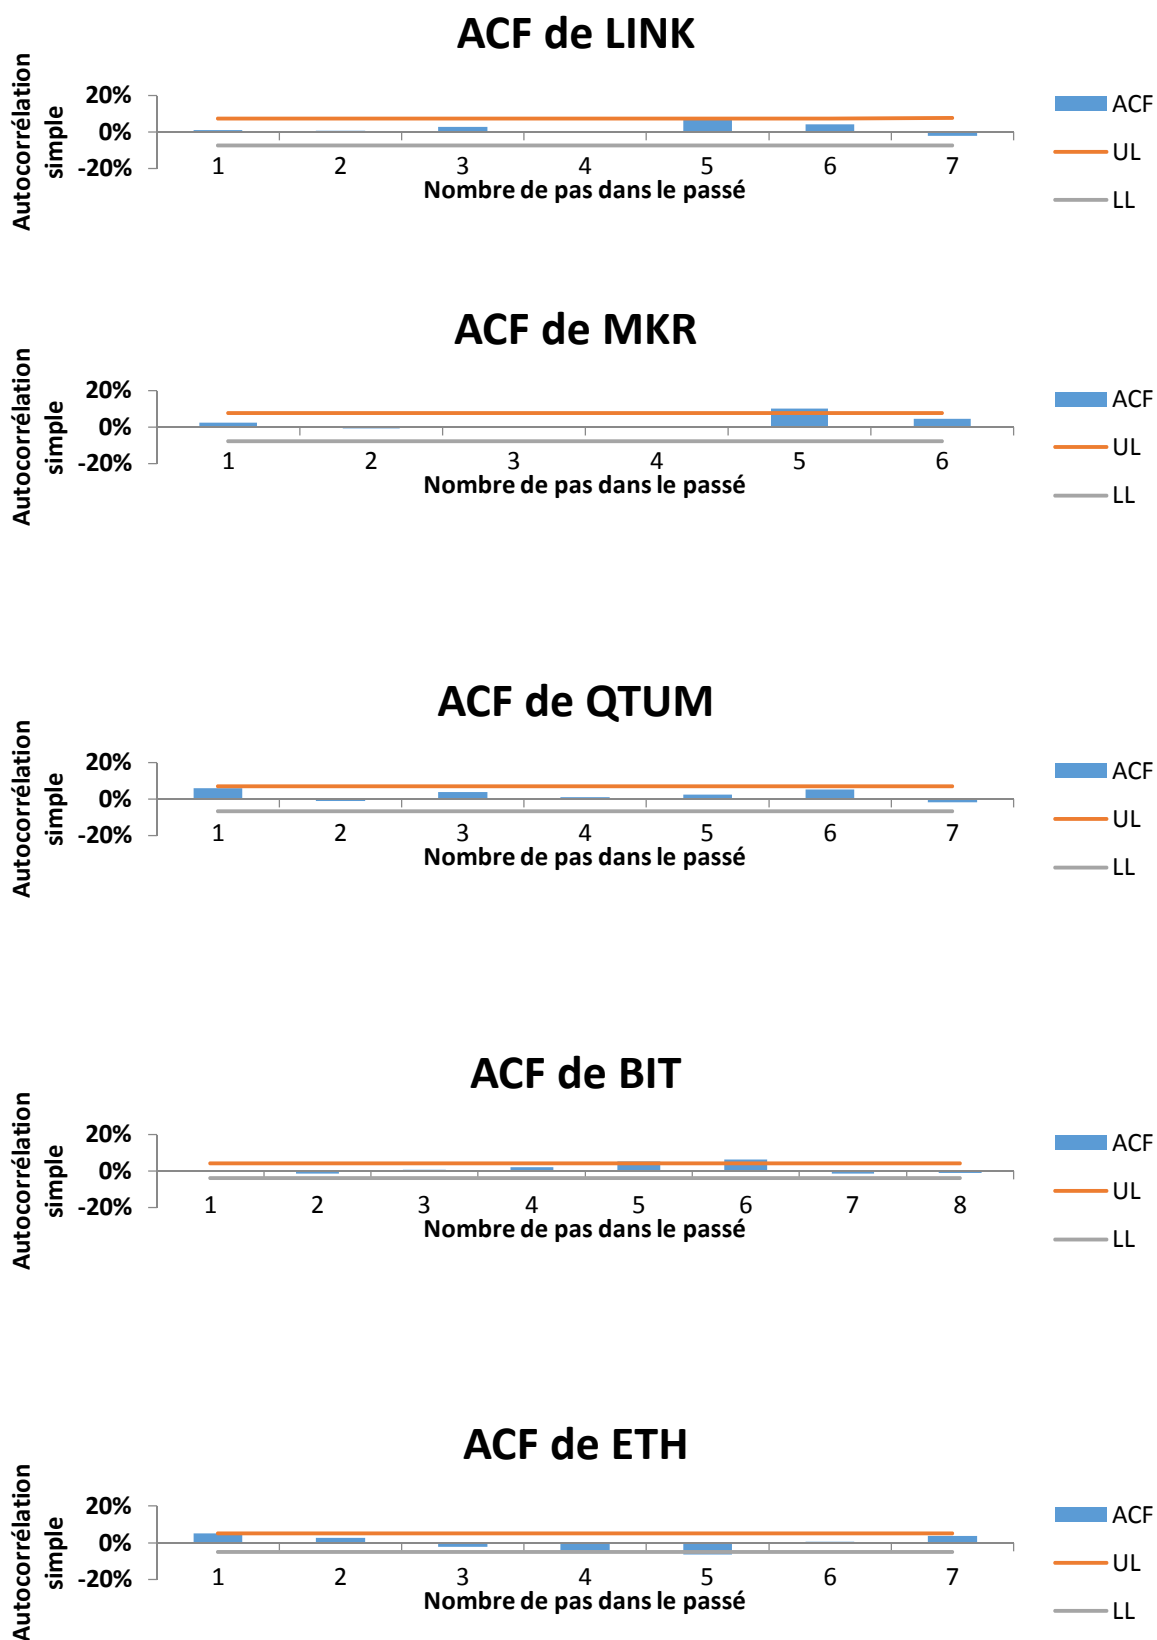




Figure 6.1. Autocorrélogrammes simples des 5 crypto-monnaies

Les autocorrélogrammes simples de la figure 6.1 nous indiquent qu'il ne semble pas y avoir d'autocorrélation significative sur la plupart des pas testés pour les 5 crypto-monnaies. En effet, la plupart des pics sont inférieurs aux limites du test de nullité. Et bien que certains pics y soient supérieurs, ceux-ci ne forment pas les motifs caractéristiques d'une haute autocorrélation. Si autocorrélation il y a, elle doit donc être très faible.


PACF de LINK



PACF de MKR



PACF de QTUM






Figure 6.2. Autocorrélogrammes partiels des 5 crypto-monnaies

Les autocorrélogrammes partiels de la figure 6.2 nous mènent au même constat que les autocorrélogrammes simples. En dépit de pics significatifs au 5^e pas pour MKR, du 6^e pour BIT et du 5^e pour ETH, on ne peut pas conclure à la présence de dépendance linéaire puisque les premiers pics, eux, sont non-significatifs.

Les résultats du test de Ljung-Box au tableau 6.1 indiquent de leur côté que les log-rendements de LINK, MKR et QTUM ne sont pas sujets à de la dépendance linéaire, la p-valeur de leur test étant supérieure à 5% pour chaque nombre de pas dans le passé. Pour ce qui est des crypto-monnaies de référence, il semble qu'en revanche, il y ait bien de la dépendance linéaire. En effet, la p-valeur du test pour BIT étant inférieure à 5% pour ses 6^e, 7^e et 8^e pas, l'hypothèse nulle d'absence d'autocorrélation pour les pas allant jusqu'à 8 doit être rejetée. Pour ETH, la p-valeur de son test étant inférieure à 5% pour ses 1^{er}, 5^e, 6^e et 7^e pas, l'hypothèse nulle doit être rejetée pour l'ensemble de ses 7 pas.

Tableau 6.1. Résultats des tests de Ljung-Box pour les log-rendements des 5 crypto-monnaies

	LINK	MKR	QTUM	BIT	ETH
--	------	-----	------	-----	-----

Nombre de pas dans le passé	Q-stat	P-valeur	Q-stat	P-valeur	Q-stat	P-valeur	Q-stat	P-valeur	Q-stat	P-valeur
1	0,0528	0,818	0,3943	0,53	2,9615	0,085	0,0207	0,886	4,0828	0,043
2	0,0668	0,967	0,4175	0,812	3,0885	0,213	0,6304	0,73	5,0292	0,081
3	0,5905	0,899	0,4196	0,936	4,3148	0,229	0,6791	0,878	5,6765	0,128
4	0,5995	0,963	0,4197	0,981	4,3839	0,357	1,7711	0,778	8,701	0,069
5	4,2108	0,519	6,996	0,221	4,8344	0,436	7,9143	0,161	14,909	0,011
6	5,4691	0,485	8,3988	0,21	7,2123	0,302	16,777	0,01	14,976	0,02
7	5,7771	0,566			7,5124	0,378	17,203	0,016	17,008	0,017
8							17,595	0,024		

Enfin, le tableau 6.2 nous montre que le nombre de Runs se trouve à l'intérieur de l'intervalle de confiance à 95% de la loi Normale approximée pour chacune des séries. On ne peut par conséquent pas rejeter l'hypothèse nulle d'absence d'autocorrélation dans les 5 cas.

Tableau 6.2. Nombre de Runs et bornes de l'intervalle de confiance à 95% de la loi normale approximée pour les 5 crypto-monnaies

	Nombre de Runs	Borne inférieure	Borne supérieure
LINK	363	329,4233	381,5753
MKR	327	300,0726	349,9274
QTUM	435	386,8153	443,1799
BIT	1180	1111,358	1205,642
ETH	773	705,2605	780,7395

De l'analyse de ces graphiques et tests, on en conclut que l'autocorrélation est extrêmement faible voire inexistante au sein des séries testées. Il serait malgré tout plus prudent de considérer la présence d'autocorrélation pour le 1^{er} pas d'ETH lors de l'étape suivante.

Section 6.2. Autorégressions

Les résultats de l'analyse de l'autocorrélation nous montrent qu'il faut utiliser une autorégression d'ordre 0 pour LINK, MKR, QTUM et BIT. Leur équation de moyenne se résumerait donc à une constante. Pour ETH, c'est une autorégression d'ordre 1 qui sera pratiquée pour capturer sa dépendance linéaire.

Tableau 6.3. Résultats de l'AR(0) pour LINK

Variable	Coefficient	Erreur-type	Stat. t	Prob.
C	0,003185	0,003244	0,982082	0,3264
R ²	0	Moyenne de la var. dép.		0,003185
R ² ajusté	0	Ecart-type de la var. dép.		0,086366
Erreur-type de régression	0,086366	AIC		-2,05904
Somme des carrés des résidus	5,281011	BIC		-2,0526
Maximum de vraisemblance	730,9297	HQC		-2,05655
Stat. Durbin-Watson	1,980367			

Tableau 6.4. Résultats de l'AR(0) pour MKR

Variable	Coefficient	Erreur-type	Stat. t	Prob.
C	0,000865	0,002525	0,342581	0,732
R ²	0	Moyenne de la var. dép.		0,000865
R ² ajusté	0	Ecart-type de la var. dép.		0,064273
Erreur-type de régression	0,064273	AIC		-2,64982
Somme des carrés des résidus	2,672739	BIC		-2,64292
Maximum de vraisemblance	859,5428	HQC		-2,64715
Stat. Durbin-Watson	1,950339			

Tableau 6.5. Résultats de l'AR(0) pour QTUM

Variable	Coefficient	Erreur-type	Stat. t	Prob.
C	-0,00129	0,002998	-0,43169	0,6661
R ²	0	Moyenne de la var. dép.		-0,00129
R ² ajusté	0	Ecart-type de la var. dép.		0,08626
Erreur-type de régression	0,08626	AIC		-2,06169
Somme des carrés des résidus	6,153567	BIC		-2,05599
Maximum de vraisemblance	854,5392	HQC		-2,0595
Stat. Durbin-Watson	1,86762			

Tableau 6.6. Résultats de l'AR(0) pour BIT

Variable	Coefficient	Erreur-type	Stat. t	Prob.
C	0,001844	0,0009	2,049268	0,0405
R ²	0	Moyenne de la var. dép.		0,001844
R ² ajusté	0	Ecart-type de la var. dép.		0,043306
Erreur-type de régression	0,043306	AIC		-3,44063
Somme des carrés des résidus	4,339651	BIC		-3,43815
Maximum de vraisemblance	3983,529	HQC		-3,43973
Stat. Durbin-Watson	2,004757			

Tableau 6.7. Résultats de l'AR(1) pour ETH

Variable	Coefficient	Erreur-type	Stat. t	Prob.
C	0,003504	0,001697	2,06471	0,0391
ETH_LOG_RETURN(-1)	0,052399	0,023029	2,27535	0,023
R ²	0,003484	Moyenne de la var. dép.		0,003649
R ² ajusté	0,002811	Ecart-type de la var. dép.		0,065402
Erreur-type de régression	0,06531	AIC		-2,618
Somme des carrés des résidus	6,317051	BIC		-2,61085
Maximum de vraisemblance	1943,244	HQC		-2,61533
Stat. F	5,17722	Stat. Durbin-Watson		2,005461
Prob(Stat. F)	0,023027			

Dans les tableaux 6.3, 6.4 et 6.5, on peut voir que la constante de l'équation de moyenne de LINK, MKR et QTUM est non-significative. Leur équation de moyenne se résumera donc à une constante, même celle-ci sera nulle. Elle prendra la forme suivante :

$$\mu_t = 0 \quad (6.1)$$

Le tableau 6.6, de son côté, montre que la constante de l'équation d'autorégression d'ordre 0 de BIT est, elle, significativement différente de 0. Par conséquent, son équation de moyenne aura la forme :

$$\mu_t = 0,001844 \quad (6.2)$$

Enfin, les résultats de l'autorégression de premier ordre pour ETH au tableau 6.7 indiquent que la constante et la variable indépendante du modèle sont toutes les deux significatives. L'équation de moyenne d'ETH s'exprimera par :

$$\mu_t = 0,003504 + 0,0524y_t \quad (6.3)$$

Section 6.3. Recherche d'effet ARCH

Le test de Ljung-Box appliqué au carré des résidus des autorégressions précédentes révèlent la présence d'un effet ARCH au sein des données. En effet, la p-valeur du test est inférieure à 5% pour chaque nombre de pas testé et ce, pour les 5 séries. L'hypothèse nulle d'absence d'autocorrélation dans le carré des résidus des 5 séries doit donc être rejetée.

Tableau 6.8. Résultats des tests de Ljung-Box sur le carré des résidus des autorégressions pour les 5 crypto-monnaies

	LINK		MKR		QTUM		BIT		ETH	
Nombre de pas dans le passé	Q-stat	P-valeur	Q-stat	P-valeur	Q-stat	P-valeur	Q-stat	P-valeur	Q-stat	P-valeur
1	17,053	0	7,4497	0,006	29,26	0	211,75	0	51,484	0
2	21,146	0	11,404	0,003	31,874	0	260,86	0	179,6	0
3	22,388	0	25,547	0	47,484	0	320,52	0	197,18	0
4	23,619	0	29,118	0	55,177	0	333,95	0	218,27	0
5	25,049	0	37,27	0	57,303	0	373,78	0	230,65	0
6	30,269	0	69,416	0	57,361	0	382,58	0	260,5	0
7	31,052	0			66,371	0	395,42	0	267,34	0
8							421	0		

Section 6.4. Recherche des modèles GARCH optimaux

Les tableaux ci-dessous comparent les valeurs des critères d'information des modèles GARCH entre eux afin de déterminer le modèle à optimal pour chacune des séries. Les valeurs surlignées en vertes sont les plus basses pour chacun de ces critères d'information.

Tableau 6.9. Valeurs des critères d'information des différents modèles GARCH testés pour LINK

	SGARCH(1,1)			IGARCH(1,1)			TGARCH(1,1)			EGARCH(1,1)			CGARCH(1,1)		
	Normal	Student	GED	Normal	Student	GED	Normal	Student	GED	Normal	Student	GED	Normal	Student	GED
AIC	-2,1993	-2,2774	-2,2688	-2,1881	-2,2721	-2,2642	-2,1973	-2,2747	-2,266	-2,2035	-2,2741	-2,2673	-2,1969	-2,2744	-2,2651
BIC	-2,1799	-2,2517	-2,2431	-2,1817	-2,2593	-2,2514	-2,1715	-2,2425	-2,2338	-2,1777	-2,2419	-2,2351	-2,1648	-2,2358	-2,2265
HQC	-2,1918	-2,2675	-2,2589	-2,1857	-2,2672	-2,2593	-2,1873	-2,2622	-2,2536	-2,1935	-2,2616	-2,2548	-2,1845	-2,2595	-2,2502

Tableau 6.10. Valeurs des critères d'information des différents modèles GARCH testés pour MKR

	SGARCH(1,1)			IGARCH(1,1)			TGARCH(1,1)			EGARCH(1,1)			CGARCH(1,1)		
	Normal	Student	GED	Normal	Student	GED	Normal	Student	GED	Normal	Student	GED	Normal	Student	GED
AIC	-2,8493	-2,981	-2,9796	-2,8263	-2,966	-2,9684	-2,8471	-2,9802	-2,9779	-2,818	-2,9734	-2,9685	-2,8522	-2,9869	-2,9832
BIC	-2,8286	-2,9534	-2,952	-2,8194	-2,9522	-2,9546	-2,8195	-2,9456	-2,9434	-2,7904	-2,9389	-2,934	-2,8177	-2,9455	-2,9418
HQC	-2,8412	-2,9703	-2,9687	-2,8236	-2,9607	-2,9631	-2,8364	-2,9668	-2,9645	-2,8073	-2,96	-2,9551	-2,8388	-2,9708	-2,9672

Tableau 6.11. Valeurs des critères d'information des différents modèles GARCH testés pour QTUM

	SGARCH(1,1)			IGARCH(1,1)			TGARCH(1,1)			EGARCH(1,1)			CGARCH(1,1)		
	Normal	Student	GED	Normal	Student	GED	Normal	Student	GED	Normal	Student	GED	Normal	Student	GED
AIC	-2,3395	-2,5266	-2,5244	-2,2987	-2,5186	-2,5143	-2,3432	-2,5243	-2,5231	-2,3365	-2,5292	-2,5244	-2,3505	-2,4019	-2,5319
BIC	-2,3224	-2,5038	-2,5016	-2,293	-2,5072	-2,5029	-2,3204	-2,4958	-2,4946	-2,3137	-2,5007	-2,4959	-2,322	-2,3677	-2,4977
HQC	-2,3329	-2,5179	-2,5156	-2,2965	-2,5142	-2,5099	-2,3345	-2,5134	-2,5121	-2,3278	-2,5182	-2,5134	-2,3396	-2,3887	-2,5188

Tableau 6.12. Valeurs des critères d'information des différents modèles GARCH testés pour BIT

	SGARCH(1,1)			IGARCH(1,1)			TGARCH(1,1)			EGARCH(1,1)			CGARCH(1,1)		
	Normal	Student	GED	Normal	Student	GED	Normal	Student	GED	Normal	Student	GED	Normal	Student	GED
AIC	-3,7391	-4,0364	-4,0335	-3,6415	-4,0125	-4,0144	-3,7384	-4,0371	-4,0336	-3,7482	-4,044	-4,0399	-3,7417	-4,0259	-4,0333
BIC	-3,7317	-4,024	-4,0211	-3,6366	-4,005	-4,0069	-3,7284	-4,0222	-4,0187	-3,7358	-4,0291	-4,025	-3,723	-4,0085	-4,0159
HQC	-3,7364	-4,0318	-4,029	-3,6397	-4,0097	-4,0116	-3,7347	-4,0317	-4,0282	-3,7437	-4,0386	-4,0344	-3,7372	-4,0196	-4,0269

Tableau 6.13. Valeurs des critères d'information des différents modèles GARCH testés pour ETH

	SGARCH(1,1)			IGARCH(1,1)			TGARCH(1,1)			EGARCH(1,1)			CGARCH(1,1)		
	Normal	Student	GED	Normal	Student	GED	Normal	Student	GED	Normal	Student	GED	Normal	Student	GED
AIC	-2,8378	-3,0069	-3,0309	-2,7025	-2,968	-2,9973	-2,8374	-3,0056	-3,0296	-2,8461	-3,0091	-3,0336	-2,835	-2,9944	-3,029
BIC	-2,8271	-2,989	-3,013	-2,6989	-2,9573	-2,9865	-2,8231	-2,9841	-3,0082	-2,8318	-2,9876	-3,0121	-2,8172	-2,9729	-3,004
HQC	-2,8338	-3,0002	-3,0242	-2,7011	-2,964	-2,9933	-2,8321	-2,9976	-3,0216	-2,8407	-3,0011	-3,0256	-2,8284	-2,9864	-3,0197

Les critères d'information de la régression de LINK nous montrent que parmi les modèles testés, le SGARCH(1,1) avec une distribution de Student pour l'innovation est celui qui convient le mieux à cette série. Pour MKR, il s'agit du CGARCH(1,1) avec une distribution de Student pour l'innovation. Pour QTUM, il s'agit du CGARCH(1,1) avec une distribution GED pour l'innovation. Enfin, pour BIT et ETH, c'est l'EGARCH(1,1) qui s'avère être optimal, avec respectivement une distribution de Student et de GED pour leurs innovations.

Les résultats concernant BIT et ETH contrastent donc avec ceux de CHU et al. (2017) qui ont plutôt montré que c'étaient l'IGARCH et le GJR-GARCH (presque équivalent au TGARCH) qui s'adaptait le mieux aux crypto-monnaies et notamment au Bitcoin et à l'Ethereum. Cependant, cette différence peut s'expliquer par le nombre moindre d'observations prises en compte ainsi que par leur nombre plus élevé de critères d'information qu'ils utilisent et de distributions pour l'innovation des modèles. La même explication peut être proposée pour justifier la différence entre les résultats de ce mémoire et ceux de KATSIAMPA (2017) qui a montré que le modèle CGARCH était optimal pour le Bitcoin.

Par ailleurs, dans ce mémoire, nous ne considérons pas les changements de régime ainsi que les ruptures structurelles qui, dans le cas du Bitcoin, peuvent conditionner l'optimalité du modèle, comme l'ont montré CHARLES et al. (2018). Il est également à noter que d'autres études portant sur le même sujet que ce mémoire testent une plus grande variété de modèles tels que le font OKUR et al. (2019) qui ont trouvé que le modèle HYGARCH était optimal pour le Bitcoin tandis que le FIGARCH avec une distribution de Student asymétrique était optimale pour Ethereum.

Section 6.5. Tests de validité des modèles GARCH optimaux

Nous pouvons constater dans le tableau 6.14 que la p-valeur du test de Ljung-Box appliqué aux résidus standardisés des modèles optimaux est supérieure à 5% pour tous les pas de LINK, MKR et QTUM. L'équation de moyenne de leur modèle GARCH optimal parvient donc à capturer l'autocorrélation de leurs log-rendements. Pour BIT et ETH, c'est l'inverse qui est constaté. Mais ceci pourrait être dû au fait que, comme précisé dans la section précédente, les modèles utilisés ne prennent pas en compte la présence de changements de régimes et de sauts structurels.

Tableau 6.14. Résultats des tests de Ljung-Box pour les résidus standardisés des modèles GARCH optimaux des 5 crypto-monnaies

	LINK		MKR		QTUM		BIT		ETH	
Nombre de pas dans le passé	Q-stat	P-valeur	Q-stat	P-valeur	Q-stat	P-valeur	Q-stat	P-valeur	Q-stat	P-valeur
1	0,1337	0,715	0,5274	0,468	0,3042	0,581	8,1097	0,004	30,147	0
2	0,4612	0,794	0,5669	0,753	0,3254	0,85	10,401	0,006	33,989	0
3	2,6046	0,457	0,6201	0,892	2,3517	0,503	13,718	0,003	42,432	0
4	2,7189	0,606	0,7982	0,939	2,3868	0,665	14,074	0,007	42,549	0
5	7,0485	0,217	9,5072	0,09	4,1059	0,534	18,42	0,002	46,766	0
6	7,0999	0,312	10,159	0,118	5,8391	0,441	35,268	0	49,528	0
7	7,5898	0,37			6,0823	0,53	35,469	0	50,451	0
8							35,667	0		



Les p-valeurs du test de Ljung-Box appliqué au carré des résidus des modèles optimaux semblent en revanche indiquer que l'ensemble de ces modèles parviennent à capturer l'effet ARCH des 5 séries. En effet, dans le tableau 6.15, on peut voir que presque toutes les p-valeurs sont supérieures à 5%.

Tableau 6.15. Résultats des tests de Ljung-Box pour le carré des résidus standardisés des modèles GARCH optimaux des 5 crypto-monnaies

	LINK		MKR		QTUM		BIT		ETH	
Nombre de pas dans le passé	Q-stat	P-valeur	Q-stat	P-valeur	Q-stat	P-valeur	Q-stat	P-valeur	Q-stat	P-valeur
1	0,2064	0,65	1,4546	0,228	0,6321	0,427	0,0099	0,921	0,0015	0,969
2	0,7253	0,696	1,4546	0,483	0,6735	0,714	0,3784	0,828	0,32	0,852
3	0,8558	0,836	1,4595	0,692	1,2831	0,733	1,217	0,749	1,2253	0,747
4	2,0605	0,725	1,5979	0,809	1,2845	0,864	2,5214	0,641	1,7845	0,775
5	2,5215	0,773	6,0634	0,3	1,472	0,916	4,805	0,44	1,7855	0,878
6	2,5223	0,866	19,977	0,003	2,7755	0,836	4,8211	0,567	1,7926	0,938
7	2,8006	0,903			2,8348	0,9	5,2852	0,625	2,9458	0,89
8							5,3991	0,714		

Les diagrammes quantile-quantile de la figure 6.3 nous permettent de constater que les résidus standardisés de LINK, MKR et BIT ont des queues de distribution plus lourdes que dans le cas d'une distribution normale. L'hypothèse selon laquelle les innovations de leur

modèle optimal respectif suivraient une loi de Student n'est donc pas invalidée par ce test. Quant à QTUM et ETH, on peut voir dans les résultats des régressions de leur modèle optimal respectif aux annexes A-7.3 et A- 7.5 que leur paramètre GED est significativement différent de 0. L'hypothèse selon laquelle les innovations de leur modèle optimal respectif seraient distribuées selon une loi normale généralisée est donc valide.






Figure 6.3. Diagrammes quantile-quantile pour une distribution théorique normale des innovations des modèles optimaux de LINK, MKR et BIT

Chapitre 7 : analyse de la volatilité

Section 7.1. Analyse des modèles GARCH optimaux

Les résultats des régressions des modèles optimaux aux annexes A- 7.1 jusque A-7.2 vont nous permettre de donner forme à ces modèles afin de mieux les visualiser. Les paramètres évoqués dans la méthodologie seront alors calculés à l'annexe A-7.6 et leurs résultats reportés au tableau 7.1 seront analysés dans cette section. On peut par ailleurs constater dans l'annexe A-7.5 que la constante de l'équation de moyenne qui était significativement différente de 0 lors de l'autorégression d'ETH ne l'est plus dans le cadre de sa modélisation GARCH.

Les équations des modèles optimaux sont les suivantes :

Modèle SGARCH(1,1) de LINK avec une distribution de Student pour l'innovation :

$$y_t = \varepsilon_t \quad (7.1)$$

$$\sigma_t^2 = 0,0599 * \varepsilon_{t-1}^2 + 0,9235 * \sigma_{t-1}^2 \quad (7.2)$$

Modèle CGARCH(1,1) de MKR avec une distribution de Student pour l'innovation :

$$y_t = \varepsilon_t \quad (7.3)$$

$$q_t = 0,9671 * (q_{t-1} - 0.0053) + 0,1215 * (\varepsilon_{t-1}^2 - \sigma_{t-1}^2) \quad (7.4)$$

$$\sigma_t^2 = q_t + 0,0884 * (\varepsilon_{t-1}^2 - q_{t-1}) - 0,8183 * (\sigma_{t-1}^2 - q_{t-1}) \quad (7.5)$$

Modèle CGARCH(1,1) de QTUM avec une distribution normale généralisée pour l'innovation :

$$y_t = \varepsilon_t \quad (7.6)$$

$$q_t = 0,0041 + 0,988 * (q_{t-1} - 0,0041) \quad (7.7)$$

$$\sigma_t^2 = q_t + 0,1475 * (\varepsilon_{t-1}^2 - q_{t-1}) + 0,6267 * (\sigma_{t-1}^2 - q_{t-1}) \quad (7.8)$$

Modèle EGARCH(1,1) de BIT avec une distribution de Student pour l'innovation :

$$y_t = 0,0015 + \varepsilon_t \quad (7.9)$$

$$\log(\sigma_t^2) = -0,3192 + 0,3904*|\varepsilon_{t-1}/\sigma_{t-1}| + 0,9821*\log(\sigma_{t-1}^2) \quad (7.10)$$

Modèle EGARCH(1,1) d'ETH avec une distribution normale généralisée pour l'innovation :

$$y_t = -0,1049* y_{t-1} + \varepsilon_t \quad (7.11)$$

$$\log(\sigma_t^2) = -0,6534 + 0,3479*|\varepsilon_{t-1}/\sigma_{t-1}| + 0,9275*\log(\sigma_{t-1}^2) \quad (7.12)$$

Tableau 7.1. Paramètres de sensibilité aux chocs, de persistance et demi-vie des modèles optimaux des 5 crypto-monnaies

	LINK	MKR	QTUM	BIT	ETH
Paramètre de sensibilité aux chocs	0,0599	0,0884	0,1475	0,3904	0,3479
Paramètre de persistance	0,9834	0,9067	0,7742	0,9821	0,9275
Demi-vie	42,41	8,08	3,71	39,38	10,21

BIT est, parmi les 5 crypto-monnaies, celle dont la volatilité est la plus sensible aux chocs. En effet, on constate qu'un choc sur ses log-returns contribue à hauteur de 39,04% à sa

volatilité. Elle est suivie dans l'ordre par ETH (34,84%), QTUM (14,75%), MKR (8,84%) et enfin, LINK (5,99%). Il est intéressant de noter que la sensibilité de la volatilité aux chocs sur les log-returns des crypto-monnaies les plus établies, BIT et ETH, est beaucoup plus forte que pour les crypto-monnaies plus récentes que sont QTUM, MKR et LINK.

En ce qui concerne la persistance des chocs sur la volatilité des log-returns, LINK est la crypto-monnaie chez qui ce phénomène est le plus important. En effet, son paramètre de persistance est de 0,9834, contre, dans l'ordre, 0,9821 pour BIT, 0,9275 pour ETH, 0,9067 pour MKR, et enfin, 0,7742 QTUM. Ce dernier est donc de son côté la crypto-monnaie chez qui les effets des chocs sur sa volatilité sont les moins persistants.



Enfin, pour que la volatilité estimée par leurs modèles optimaux respectifs se trouve à mi-chemin entre le niveau actuel de volatilité (30 août 2019 pour ces échantillons) et le niveau de volatilité non-conditionnel, cela prendrait, dans l'ordre, 43 jours ouvrables pour LINK, 40 jours ouvrables pour BIT, 11 jours ouvrables pour ETH, 9 jours ouvrables pour MKR et 4 jours ouvrables pour QTUM. Il est important de constater la différence entre la demi-vie de BIT trouvée dans l'analyse de ce mémoire et celle telle que trouvée par JOHN et al. (2019) qui ne valait que 3 jours seulement. Cependant, cette différence pourrait s'expliquer par le nombre d'observations prises en compte et le modèle utilisé (PGARCH dans le cas de ces chercheurs).

Dans le cas de BIT et ETH, les coefficients des modèles EGARCH censés nous indiquer si la volatilité des log-returns réagit de manière asymétrique aux chocs se trouve être non-significatifs malgré le fait que l'EGARCH s'avère être leur modèle optimal. On pourrait donc en conclure que leur volatilité n'a pas de comportement asymétrique.

Section 7.2. Analyse de la volatilité conditionnelle

On constate sur la figure 7.1 que la volatilité conditionnelle de LINK, MKR et QTUM a globalement baissé avec le temps, ce qui est moins clair avec BIT et ETH. Par ailleurs, alors que la volatilité conditionnelle de MKR, QTUM et ETH se stabilise (de manière relative) en évoluant dans un couloir qui se rétrécit progressivement vers la fin de leur série, celle de LINK et BIT ont plutôt tendance à alterner entre des phases de basse et haute volatilité conditionnelle.

La volatilité conditionnelle de MKR et QTUM ayant été modélisée à partir du CGARCH, l'on peut décomposer celle-ci en composantes permanente et transitoire. D'abord, on peut observer que MKR a des composantes permanente et transitoire moins stable que dans le cas de QTUM. De plus, la composante transitoire de MKR varie autour de 0 avec des pics au-dessus et au-dessous de sa tendance générale. Celle de QTUM évolue avec une tendance dans les négatifs, mais les pics pointent essentiellement vers le haut et passent occasionnellement dans les positifs.








Figure 7.1. Evolution des écarts-types conditionnels journaliers des 5 crypto-monnaies

Conclusion

Le sujet de ce mémoire ayant été l'étude de la volatilité de crypto-monnaies et ayant constaté que certaines d'entre elles n'avaient pas fait l'objet d'une étude spécifique de leur volatilité, il a été choisi dans le cadre de ce mémoire de s'y intéresser. Ainsi, Chainlink, Maker et Quantum ont été choisis en raison de leur importance relative et du fait du peu de recherches dont ils ont fait l'objet. Bitcoin et Ethereum ont été rajoutés pour disposer d'une base de comparaison.

Ce mémoire s'est principalement inspiré de TSAY (2010) pour sa méthodologie, suivant le même parcours pour construire des modèles GARCH(1,1) pouvant représenter les 5 séries de données et plus particulièrement, leur volatilité conditionnelle. Par la suite, l'on a suivi la méthodologie de CHU et al. (2017) pour sélectionner le modèle GARCH(1,1) le plus adéquat pour représenter chacune des séries.

Cette recherche a montré que de tous les modèles testés, le SGARCH(1,1) avec une distribution de Student pour l'innovation est optimal pour LINK, le CGARCH(1,1) avec une distribution de Student pour l'innovation l'est pour MKR, celui de QTUM est le CGARCH(1,1) avec une distribution GED pour l'innovation, et enfin, c'est l'EGARCH(1,1) qui s'avère être optimal pour BIT et ETH, avec respectivement une distribution de Student et de GED pour leurs innovations.

L'analyse des modèles GARCH(1,1) optimaux a par ailleurs mis en lumière le fait que, dans l'ordre, BIT et ETH ont une volatilité plus sensible aux chocs que QTUM, MKR et LINK. De plus, on a pu constater que l'effet des chocs étant plus persistants sur LINK que sur les autres crypto-monnaies. QTUM serait quant à elle, la crypto-monnaie la moins sujette à la persistance des chocs. Ces analyses ont également montré que la demi-vie était de 43 jours ouvrables pour LINK, 40 jours ouvrables pour BIT, 11 jours ouvrables pour ETH, 9 jours ouvrables pour MKR et 4 jours ouvrables pour QTUM. A côté de cela, la non-significativité des coefficients des modèles EGARCH censés nous indiquer si la volatilité des log-returns

réagit de manière asymétrique aux chocs semblent plutôt indiquer que la volatilité de BIT et ETH n'a pas de comportement asymétrique.

Enfin, la modélisation de la volatilité conditionnelle des 5 crypto-monnaies a montré que principalement celle de MKR et QTUM a tendance à baisser et à se stabiliser avec le temps. Par ailleurs, ces 2 crypto-monnaies se trouvent être celles dont le modèle GARCH(1,1) optimal leur permet de décomposer leur volatilité conditionnelle en composantes permanente et transitoire.

Il est à noter cependant que ce mémoire eut recours à une variété moindre de modèles et de distributions pour les innovations comparé à d'autres études. Il serait donc intéressant d'appliquer d'autres modèles et distributions à ces 3 crypto-monnaies moins connues que sont LINK, MKR et QTUM. De plus, leur récence implique un nombre moins élevé d'observations que pour d'autres crypto-monnaies plus établies. Une étude comparable à celle de ce mémoire mais disposant de plus d'observations serait également intéressante.

Bibliographie

Articles et ouvrages

BARIVIERA, A., F., BASGALL, M., J., HASPERUE, W. et MARCELO, N. (2017), "Some stylized facts of the Bitcoin market", *Physica A*, pp. 1-20

BAUR, D., G. et DIMPFL, T. (2018), "Asymmetric volatility in cryptocurrencies", *Economics Letters*, 173, pp. 1-11

BERENTSEN, A. et SCHÄR, F. (2018), "A Short Introduction to the World of Cryptocurrencies", *Federal Reserve Bank of St. Louis Review*, 100, pp.4-12

BOURI, E., GIL-ALANA, L. A., GUPTA, R. et ROUBAUD, D. (2019), "Modelling long memory volatility in the Bitcoin market: Evidence of persistence and structural breaks", *International Journal of FINANCE & ECONOMICS*, 24, pp. 412-426

- CAMPBELL, J., Y., LO, A., W. et MACKINLAY, A., C. (1996), *The Econometrics of Financial Markets*, Princeton University Press, New Jersey
- CAPORALE, G., M. et ZEKOKH, T. (2019), “Modelling volatility of cryptocurrencies using Markov-Switching GARCH models”, *Research in International Business and Finance*, 48, pp. 143-155
- CATANIA, L., GRASSI, S. et RAVAZZOLO, F. (2018), “Forecasting Cryptocurrencies Financial Time Series”, *CAMP Working Paper Series*, 5, pp. 1-26
- CHAN, H., N. (2010), *Time Series- Applications to Finance*, John Wiley & Sons, Inc., New Jersey
- CHAN, S., CHU, J., NADARAJAH, S. et OSTERRIEDER, J. (2017), “A Statistical Analysis of Cryptocurrencies”, *Journal of Risk and Financial Management*, 10, pp. 1-23
- CHARFEDDINE, L. et MAOUCHI, Y. (2019), “Are shocks on the returns and volatility of cryptocurrencies really persistent?”, *Finance Research Letters*, 28, pp. 423-430
- CHARLES, A. et DARNE, O. (2019), “Volatility estimation for cryptocurrencies: Further evidence with jumps and structural breaks”, *Economics Bulletin*, 39, pp. 954-968
- CHU, J., CHAN, S., NADARAJAH, S. et OSTERRIEDER, J. (2017), “GARCH Modelling of Cryptocurrencies”, *Journal of Risk and Financial Management*, 10, pp. 1-15
- DIVINO, J.A., MCALEER, M., (2009), “Modelling sustainable international tourism demand to the Brazilian Amazon”, *Environmental Modelling and Software*, pp. 1411-1419
- GRONWALD, M. (2014), “The Economics of Bitcoins – Market Characteristics and Price Jumps”, *CESifo Working Papers*, pp. 1-11
- HOUBEN, R. et SNYERS, A. (2018), “Cryptocurrencies and blockchain: Legal context and implications for financial crime, money laundering and tax evasion”, *TAX3 committee*, pp. 20-27
- JOHN, A., LOGUBAYOM, A., I. et NERO, R. (2019), “Half-Life Volatility Measure of the Returns of Some Cryptocurrencies”, *Journal of Financial Risk Management*, 8, pp. 15-28

- KATSIAMPA, P. (2017), “Volatility estimation for Bitcoin: A comparison of GARCH models”, *Economics Letters*, 158, pp. 3-6
- KATSIAMPA, P. (2019), “An empirical investigation of volatility dynamics in the cryptocurrency market”, *Research in International Business and Finance*, 50, pp. 322-335
- LANSKY, J. (2018), “Possible State Approaches to Cryptocurrencies”, *Journal of Systems Integration*, 1, p. 19
- OESTERRIEDER, J., LORENZ, J. et STRIKA, M. (2016), “Bitcoin and Cryptocurrencies—Not for the Faint-Hearted”, *International Finance and Banking*, 4, pp. 56-94
- OKUR, M., ÇATIKKAŞ, Ö. et KAYA, P.(2019), “Long Memory in the Volatility of Selected Cryptocurrencies: Bitcoin, Ethereum and Ripple”, *ResearchGate*, pp. 1-18
- PHILLIP, A., CHAN, J., S., K. et PEIRIS, L. (2017), “A new look at Cryptocurrencies”, *Economics Letters*, 163, pp. 1-9
- SONG, J., Y., CHANG, W. et SONG, J., W. (2019), “Cluster analysis on the structure of the cryptocurrency market via Bitcoin-Ethereum filtering”, *Physica A: Statistical Mechanics and its Applications*, 527, pp. 1-29
- TSAY, R., S. (2010), *Analysis of Financial Time Series – 3rd edition*, John Wiley & Sons, Inc., New Jersey
- ZHANG, Y., CHAN, S. et NADARAJAH, S. (2019), “Extreme value analysis of high-frequency cryptocurrencies”, *High Frequency*, 2, pp. 61-69

Sites internet

<https://coinmarketcap.com/all/views/all/>

https://en.wikipedia.org/wiki/David_Chaum#cite_note-Greenberg-2

https://fr.wikipedia.org/wiki/Test_de_Jarque-Bera

<https://support.sas.com/kb/33/092.html>

<http://www.real-statistics.com/time-series-analysis/stochastic-processes/dickey-fuller-test/>

Annexes

A- 7.1. Résultats de la régression du modèle SGARCH(1,1) de LINK avec une distribution de Student pour l'innovation

Variable	Coefficient	Erreur-type	Stat. z	Prob.
Equation de variance				
C	0,000112	6,47E-05	1,72513	0,0845
RESID(-1)^2	0,059919	0,021266	2,817607	0,0048
GARCH(-1)	0,923523	0,024038	38,4187	0
Distrib. t-ddl	5,027957	0,976616	5,148348	0
R ²	-0,00136	Moyenne de la var. dép.	0,003185	
R ² ajusté	0,00005	Ecart-type de la var. dép.	0,086366	
Erreur-type de régression	0,086364	AIC	-2,2774	
Somme des carrés des résidus	5,288206	BIC	-2,25165	
Maximum de vraisemblance	811,3381	HQC	-2,26745	
Stat. Durbin-Watson	1,977673			

A-7.2. Résultats de la régression du modèle CGARCH(1,1) de MKR avec une distribution de Student pour l'innovation

Variable	Coefficient	Erreur-type	Stat. z	Prob.
Equation de variance				
C(1)	0,005308	0,00395	1,343752	0,179
C(2)	0,967119	0,028828	33,54784	0
C(3)	0,121544	0,044432	2,735524	0,0062
C(4)	0,08841	0,038599	2,290488	0,022
C(5)	-0,81827	0,096757	-8,45701	0
Distrib. t-ddl	3,87073	0,64867	5,967175	0
R ²	-0,00018	Moyenne de la var. dép.		0,000865
R ² ajusté	0,001362	Ecart-type de la var. dép.		0,064273
Erreur-type de régression	0,064229	AIC		-2,98691
Somme des carrés des résidus	2,673223	BIC		-2,94549
Maximum de vraisemblance	973,7596	HQC		-2,97084
Stat. Durbin-Watson	1,949985			

A-7.3. Résultats de la régression du modèle CGARCH(1,1) de QTUM avec une distribution normale généralisée pour l'innovation

Variable	Coefficient	Erreur-type	Stat. z	Prob.
Equation de variance				
C(1)	0,004134	0,001071	3,860836	0,0001
C(2)	0,987984	0,004198	235,3738	0
C(3)	0,015114	0,009798	1,542505	0,123
C(4)	0,147457	0,055975	2,634333	0,0084
C(5)	0,62671	0,123637	5,068942	0
Paramètre GED	0,982735	0,057578	17,06782	0
R ²	-0,00023	Moyenne de la var. dép.		-0,00129
R ² ajusté	0,000983	Ecart-type de la var. dép.		0,08626
Erreur-type de régression	0,086218	AIC		-2,53194

Somme des carrés des résidus	6,154953	BIC	-2,49775
Maximum de vraisemblance	1054,224	HQC	-2,51883
Stat. Durbin-Watson	1,867199		

A- 7.4. Résultats de la régression du modèle EGARCH(1,1) de BIT avec une distribution de Student pour l'innovation

Variable	Coefficient	Erreur-type	Stat. z	Prob.
C	0,001508	0,000424	3,558855	0,0004
Equation de variance				
C(2)	-0,31924	0,044081	-7,24198	0
C(3)	0,390364	0,057005	6,847865	0
C(4)	0,032785	0,022327	1,468364	0,142
C(5)	0,982085	0,005549	176,9889	0
Distrib. t-ddl	2,516772	0,174222	14,44575	0
R ²	-0,00006	Moyenne de la var. dép.		0,001844
R ² ajusté	-0,00006	Ecart-type de la var. dép.		0,043306
Erreur-type de régression	0,043307	AIC		-4,044
Somme des carrés des résidus	4,339913	BIC		-4,0291
Maximum de vraisemblance	4686,927	HQC		-4,03857
Stat. Durbin-Watson	2,004636			

A- 7.5. Résultats de la régression du modèle EGARCH(1,1) d'ETH avec une distribution normale généralisée pour l'innovation

Variable	Coefficient	Erreur-type	Stat. z	Prob.
ETH_LOG_RETURN(-1)	-0,10486	0,019322	-5,42679	0

Equation de variance				
C(2)	-0,65338	0,125498	-5,20633	0
C(3)	0,34788	0,051657	6,734393	0
C(4)	0,020524	0,028209	0,727567	0,4669
C(5)	0,92748	0,018381	50,45838	0
Paramètre GED	0,894382	0,043462	20,57829	0
R ²	-0,03152	Moyenne de la var. dép.	0,003649	
R ² ajusté	-0,03152	Ecart-type de la var. dép.	0,065402	
Erreur-type de régression	0,066425	AIC	-3,03359	
Somme des carrés des résidus	6,53897	BIC	-3,01214	
Maximum de vraisemblance	2255,407	HQC	-3,0256	
Stat. Durbin-Watson	1,675694			

A- 7.6. Calculs des paramètres de sensibilité, de persistance et de la demi-vie pour chacun des modèles optimaux des 5 crypto-monnaies

LINK :

Paramètre de sensibilité = 0,0599

Paramètre de persistance = 0,0599+0,9235=0,9834

Demi-vie = $\log(0,9834/2) / \log(0,9834) = 42,41$

MKR :

Paramètre de sensibilité = 0,0884

Paramètre de persistance = 0,0884+0,8183 = 0,9067

Demi-vie = $\log(0,9067/2) / \log(0,9067) = 8,08$

QTUM :

Paramètre de sensibilité = 0,1475

Paramètre de persistance = 0,1475+0,6267 = 0,7742

Demi-vie = $\log(0,7742/2) / \log(0,7742) = 3,71$

BIT :

Paramètre de sensibilité = 0,3904

Paramètre de persistance = 0,9821

Demi-vie = $\log(0,9821) / \log(0,9821) = 39,38$

ETH :

Paramètre de sensibilité = 0,3479

Paramètre de persistance = 0,9275

Demi-vie = $\log(0,9275/2) / \log(0,9275) = 10,21$